



Svetlana Roudolfovna Chemetova

Mestre em Engenharia Electrotécnica e
Computadores

**Previsão de consumo de energia
eléctrica nos principais pontos
injectores da rede de transporte na
rede de distribuição**

Dissertação para obtenção do Grau de Doutor em
Engenharia Electrotécnica e Computadores

Orientador: Paulo Jorge da Costa Santos, Professor Adjunto,
Escola Superior de Tecnologia de Setúbal,
Instituto Politécnico de Setúbal

Co-orientador: Mário Ventim Neves, Professor Auxiliar,
Faculdade de Ciências e Tecnologia,
Universidade Nova de Lisboa

Júri:

Presidente: Prof. Doutor Paulo da Costa Luís da Fonseca Pinto

Arguentes: Prof. Doutor Jorge Alberto Mendes de Sousa

Prof. Doutor Álvaro Filipe Peixoto Cardoso de Oliveira Gomes

Vogais: Prof. Doutor Paulo da Costa Luís da Fonseca Pinto

Prof. Doutor João Miguel Murta Pina

Prof. Doutor Pedro Miguel Ribeiro Pereira

Prof. Doutor Paulo Jorge da Costa Santos



FACULDADE DE
CIÊNCIAS E TECNOLOGIA
UNIVERSIDADE NOVA DE LISBOA

[Setembro 2018]

Previsão de consumo de energia eléctrica nos principais pontos injectores da rede de transporte na rede de distribuição.

Copyright © Svetlana Roudolfovna Chemetova, Faculdade de Ciências e Tecnologia, Universidade Nova de Lisboa.

A Faculdade de Ciências e Tecnologia e a Universidade Nova de Lisboa têm o direito, perpétuo e sem limites geográficos, de arquivar e publicar esta dissertação através de exemplares impressos reproduzidos em papel ou de forma digital, ou por qualquer outro meio conhecido ou que venha a ser inventado, e de a divulgar através de repositórios científicos e de admitir a sua cópia e distribuição com objectivos educacionais ou de investigação, não comerciais, desde que seja dado crédito ao autor e editor.

Agradecimentos

Expresso os meus sinceros agradecimentos a todos aqueles que contribuíram directa e indirectamente para a realização do presente trabalho, em especial ao meu orientador científico, Professor Doutor Paulo Santos, pela proposta do tema, pelo empenho com que fomentou o desenvolvimento do trabalho e pelo seu imprescindível apoio no acompanhamento e supervisão da dissertação, e ao co-orientador científico Professor Doutor Mário Ventim Neves, pela disponibilidade sempre mostrada e pelas valiosas contribuições na resolução dos problemas encontrados.

Ao Professor Doutor Armando Pires, o meu mais grato agradecimento pela ajuda e boas sugestões que contribuíram da melhor forma para a conclusão do presente trabalho.

Desejo ainda agradecer a prestável colaboração e o encorajamento dos meus colegas de trabalho da Escola Superior de Tecnologia do Instituto Politécnico de Setúbal, especialmente à colega do trabalho e de curso de doutoramento Elena Baikova, pelo apoio moral e a colaboração na parte escolar de doutoramento.

Agradeço às empresas EDP Distribuição e Instituto Português do Mar e da Atmosfera pela disponibilidade dos dados que foram usados nos ensaios do modelo de previsão desenvolvido.

Finalmente expresso a minha gratidão à minha família, pela amizade e apoio sempre demonstrados. Ao meu marido Francisco, pelo apoio e grande ajuda na parte linguística da redacção da dissertação.

Resumo

A previsão da potência eléctrica é um auxiliar fundamental para o planeamento, operação e exploração dos Sistemas de Energia Eléctrica (SEE). A importância deste tipo de algoritmos tornou-se mais significativa com a introdução do mercado de energia eléctrica e com a consequente desverticalização do sector energético.

O objectivo desta dissertação consiste no desenvolvimento de um modelo de previsão do diagrama de carga diário e a consequente previsão da potência de ponta nos principais pontos injectores da rede de transporte em Portugal continental. Cada ponto injector corresponde a uma ou mais subestações encarregues de estabelecer a interligação entre a rede de transporte e a rede de distribuição.

Para o desenvolvimento do trabalho foram utilizados os seguintes dados: valores de potência activa registados pelo sistema de telecontagem da EDP Distribuição e as séries temporais climáticas obtidas do Instituto Português do Mar e da Atmosfera. O horizonte de previsão é de curto prazo: de uma hora e de 24 horas.

Os resultados da previsão foram obtidos através de uma metodologia regressiva com base numa aproximação da composição do vector de entrada. O processamento dos dados históricos da carga resulta numa combinação de diversos sinais, onde são definidos patamares de carga de acordo com o perfil de cada ponto injector e um sinal aleatório. Assim, desenvolveu-se uma metodologia híbrida de previsão de cargas, utilizando as vantagens das técnicas baseados nas redes neuronais combinadas com uma nova abordagem de composição do vector de entrada dessas redes.

Este trabalho foi suportado pela simulação de casos de estudo reais, sendo as três cidades representativas Lisboa, Porto e Évora. Adicionalmente, foram acrescentados dados da Rede Nacional de Transporte (RNT), agregando todo o consumo de energia eléctrica em Portugal Continental.

Até à presente data, encontra-se a decorrer um projecto-piloto de introdução de tarifas dinâmicas no sistema tarifário português, assegurado por Entidade Reguladora dos Serviços Energéticos (ERSE). Desde modo, procedeu-se à avaliação dos métodos analisados neste sistema tarifário.

Palavras Chaves: redes de distribuição de energia eléctrica, diagrama de carga, pontos injectores, previsão de carga, redes neuronais, potência de ponta.

Abstract

Load forecast is a fundamental tool for planning, operation and investigation of Electrical Power Systems. These algorithms have gained national interest after the open electric energy market establishment into Portuguese energetic sector.

The present work aims to develop a model prediction of load diagram, and consequently the load peak in the main injection points of transport and distribution network grids in Portugal. An injection point defines one or more substations that links transport and distribution grids.

The active power data was facilitated by Distribution System Operator (EDP Distribuição) and time series of meteorology by Portuguese Institute for Sea and Atmosphere (IPMA).

A short-term load forecast was selected and focused on next-hour, and next-day time horizon.

Regressive methodology was proposed based on a construction of the input vector. The historical data was combined into signals that defined load levels, according to the profile of chosen injection point and random signal. The development of a hybrid methodology took the advantages of artificial neural networks, combining an innovate approach of input vector configuration.

A real-life case studies were simulated for tree cities: Lisbon, Oporto and Évora. Furthermore, data from the Portugal Transmission Network was added to enhance the study.

Currently, a pilot-project focused on dynamic prices in Portuguese tariff system is run by ERSE, that may potentiate a method analysis test in this concrete tariff system.

Keywords: distribution networks; load diagram; injection points; load forecasting; neural networks; load peak.

Conteúdo

Capítulo 1	Introdução	1
1.1	Enquadramento e Motivação	2
1.2	Questões de Investigação	7
1.2.1	Introdução ao problema de previsão da carga eléctrica	7
1.2.2	Problemas de investigação	9
1.2.3	Hipóteses	9
1.3	Metodologia de investigação	10
1.3.1	Contribuição	10
1.3.2	Plano de trabalho	11
1.4	Metodologia de validação	12
1.5	Estrutura da tese	14
Capítulo 2	O estado da arte	17
2.1	Introdução	18
2.2	Os horizontes de previsão	18
2.3	Métodos de previsão da carga	19
2.4	Conclusões	26
Capítulo 3	Recolha de informação para os casos de estudo	27
3.1	Introdução	28
3.2	Descrição de subestações usadas para os casos de estudo	33
3.2.1	Évora	33
3.2.2	Porto	38

3.2.3 Lisboa	42
3.3 Processamento inicial de dados de carga eléctrica	47
3.4 Dados meteorológicos	49
3.5 Conclusões.....	59
 Capítulo 4 Modelo de previsão proposto	61
4.1 Introdução.....	62
4.2 Redes Neurais Artificiais: Breve Referencial Teórico.....	64
4.3 Construção do vector de entrada	66
4.3.1 Introdução	66
4.3.2 Autocorrelação das séries temporais de potência activa	67
4.3.3 A inclusão no vector de entrada das variáveis de patamares de carga e do sinal aleatório	69
4.3.4 Obtenção de padrões de diagrama de carga na forma de patamares	70
4.3.5 Injecção do sinal aleatório	77
4.4 Conclusões.....	78
 Capítulo 5 Implementação do modelo e os resultados obtidos	81
5.1 O meio computacional usado para a previsão da carga	82
5.2 Previsão para a hora seguinte	84
5.3 Previsão para 24 horas seguintes	91
5.4 Rede Nacional de Transporte como mais um caso de estudo	104
5.5 Conclusões.....	109
 Capítulo 6 Previsão das pontas diárias do diagrama de carga	111
6.1 Introdução.....	112
6.2 Resultados de previsão da ponta diária do diagrama de carga.....	115
6.3 Conclusões.....	121
 Capítulo 7 Previsão das cargas em ambiente de gestão da procura.....	123
7.1 Introdução.....	124

7.2 Avaliação dos métodos de previsão da potência de ponta em ambiente de tarifas dinâmicas.....	126
7.2.1 Ambiente sem restrições na definição dos períodos críticos.....	127
7.2.2 Ambiente de projecto-piloto de introdução de tarifas dinâmicas.....	129
7.3 Avaliação do impacto económico da previsão num sistema de tarifas dinâmicas.....	138
7.3.1 Impacto em ambiente sem restrições na definição dos períodos críticos.....	139
7.3.2 Ambiente de projecto-piloto de introdução de tarifas dinâmicas.....	142
7.4 Conclusões.....	145

Capítulo 8 Conclusões e Perspectivas de Trabalhos Futuros 147

8.1 Principais resultados e contributos	148
8.2 Publicações.....	150
8.3 Perspectivas de Desenvolvimento Futuro.....	151

Capítulo 9 Referências..... 153

Capítulo 10 Anexos 161

Anexo 1. Dados fornecidos pelo sistema de telecontagem de EDP Distribuição	162
Anexo 2. Dados meteorológicos.....	164

Lista de Figuras

Figura 1-1: As principais funções de Sistemas de Gestão da Distribuição.....	3
Figura 1-2: Sistemas de Energia Eléctrica: do passado até futuro (<i>smart grids</i>). Obtido de (Fagundes, 2013).....	6
Figura 1-3: Potência real e prevista num Diagrama de Carga diário.....	8
Figura 1-4: Exemplo de potência instantânea e potência média tomada (baseado no (Kersting, 2007)).	8
Figura 1-5: Os métodos clássicos de investigação. Adaptado de (Camarinha-Matos, 2010).	12
Figura 2-1: Esquema geral de etapas de <i>Knowledge-Discovery in Databases</i> , obtido de (Rosário, 2014).....	22
Figura 3-1: Arquitectura do <i>InovGrid</i> , obtido de (Ferreira P. , 2012).	30
Figura 3-2: Mapa de Portugal, incluindo as redes MAT, as cidades em estudo com os perfis de carga e os principais pontos injetores da rede de transporte na rede de distribuição de energia eléctrica (60kV).	32
Figura 3-3: Aspecto topológico das redes de 150, 60, 30 e 15 kV na zona da cidade de Évora e arredores.	33
Figura 3-4: As redes que alimentam a cidade de Évora, fragmento ampliado.	34
Figura 3-5: Topologia da rede MT 15 kV que alimenta a cidade de Évora.....	34
Figura 3-6: Esquema unifilar de SEs de abastecimento de energia eléctrica à cidade de Évora.	35
Figura 3-7: Diagrama de carga de uma semana. 9 – 15 de Dezembro, Évora.	36
Figura 3-8: Diagrama de carga de duas semanas. 7 – 20 de Janeiro, Évora.	37
Figura 3-9: Diagrama de carga anual, Évora.	37
Figura 3-10: Diagrama de carga semanal de Inverno e de Verão, Évora.	38
Figura 3-11: Esquema unifilar de SEs de abastecimento de energia eléctrica à cidade do Porto.	39
Figura 3-12: Diagrama de carga de uma semana de Primavera, 14-20 de Abril de 2014, Porto.	40

Figura 3-13: Diagrama de carga de semana de 1 – 7 de Setembro de 2014, Porto.....	41
Figura 3-14: Diagrama de carga do ano 2014, Porto.....	41
Figura 3-15: Esquema simplificado das subestações e linhas de alta tensão do abastecimento de energia eléctrica da cidade de Lisboa.	42
Figura 3-16: Esquema unifilar de SEs de abastecimento de energia eléctrica à cidade de Lisboa.	43
Figura 3-17: Diagrama de carga de semana de 9 – 15 de Junho de 2014, Lisboa.	45
Figura 3-18: Diagrama de carga de semana de 10 – 16 de Fevereiro de 2014, Lisboa.	45
Figura 3-19: Evolução da potência activa da cidade de Lisboa durante o ano 2014.	46
Figura 3-20: Diagramas de carga de duas semanas, para os três casos de estudo.	47
Figura 3-21: Modelagem linear para a substituição de valores de carga perdidos.	49
Figura 3-22: Uma leitura de carga corrompida.....	49
Figura 3-23: A evolução diária da temperatura média e humidade, Portugal continental e a cidade de Porto. 03/2012 -02/2013. Obtido de (Rodrigues, 2014).	50
Figura 3-24: A evolução diária da potência média e temperatura média. Lisboa, 2014.	52
Figura 3-25: A evolução diária da potência média e temperatura mínima. Lisboa, 2014.	52
Figura 3-26: A evolução diária da potência média e temperatura máxima. Lisboa, 2014.....	53
Figura 3-27: A evolução diária da potência média e humidade relativa média. Lisboa, 2014.	54
Figura 3-28: Potência média diária vs. temperatura média diária. Lisboa, 2014.....	55
Figura 3-29: Potência média diária vs. temperatura mínima diária. Lisboa, 2014.	56
Figura 3-30: Potência média diária vs. temperatura máxima diária. Lisboa, 2014.....	56
Figura 3-31: Potência média diária vs. humidade relativa média diária. Lisboa, 2014.	57
Figura 4-1: Diagrama de blocos do modelo de previsão	63
Figura 4-2: Esquema conceptual do modelo de previsão desenvolvido.	64
Figura 4-3: Esquema de um neurónio artificial.	64
Figura 4-4: A variável de previsão $P(t)$ e as duas anteriores, $P(t-1)$ e $P(t-2)$	67
Figura 4-5. Evolução dos coeficientes de autocorrelação de potência activa.	68
Figura 4-6: Sequência simbolizada de implementação do sinal aleatório injectado no diagrama de patamares.....	69
Figura 4-7: Um diagrama de carga diário com os respectivos patamares de carga, obtido de (Farias, 2008).....	71

Figura 4-8: Diagrama diário médio de Inverno com os níveis de patamares correspondentes, Lisboa 2014.	74
Figura 4-9: Diagrama diário médio de Inverno com os 3 níveis de patamares correspondentes, Porto 2014.	75
Figura 4-10: Diagrama diário médio de Verão com os 3 níveis de patamares correspondentes, Porto 2014.	75
Figura 4-11: O diagrama diário médio de carga de Inverno com os respectivos 3 níveis de patamares. Évora, 2014.	76
Figura 4-12: O diagrama diário médio de carga de Verão com os respectivos 2 níveis de patamares. Évora, 2014.	76
Figura 4-13: Exemplo de sinal aleatório injectado no diagrama de patamares (cidade de Évora, dia útil de Inverno).	78
Figura 5-1: Esquema simplificado da previsão de potência para a hora seguinte.	84
Figura 5-2: Vector de entrada final, composição simples.	85
Figura 5-3: Variáveis de potências e gradientes que fazem parte do vector de entrada inicial.....	86
Figura 5-4: Vector de entrada final, com patamares e sinal aleatório.....	87
Figura 5-5: Diagrama de carga real e previsto, cidade de Évora.	88
Figura 5-6: Diagrama de carga real e previsto, cidade do Porto.....	89
Figura 5-7: Diagramas de carga no período de uma semana, cidade de Évora.	89
Figura 5-8: Diagramas de carga no período de uma semana, cidade do Porto.	90
Figura 5-9: Percentagem de erro no período de duas semanas.	91
Figura 5-10: Esquema geral do modelo de previsão para o dia seguinte.....	92
Figura 5-11: Composição do vector de entrada final para a previsão de carga para o dia seguinte.	94
Figura 5-12: Resultados de previsão para um dia de Inverno, 15.12.2015, Lisboa.	96
Figura 5-13: Resultados de previsão para um dia de Verão, 30.06.2015, Lisboa.....	97
Figura 5-14: Resultados de previsão para uma semana de Verão, 13-19 de Junho de 2015, Lisboa.	98
Figura 5-15: Evolução da percentagem de erro para a previsão apresentada na figura 5-14.	98
Figura 5-16: Percentagem de erro para 10 dias de Inverno: 14.12 – 27.12 2015, Lisboa.....	99
Figura 5-17: Percentagem de erro para 10 dias de Verão: 15.06 – 24.06 2015, Évora.....	100
Figura 5-18: Resultados de previsão para um mês de Verão, Julho de 2015, Lisboa.....	100

Figura 5-19: Evolução da percentagem de erro para a previsão apresentada na figura 5-18.	101
Figura 5-20: Esquema de ligações de RNT. Obtido de (REN, 2017).	105
Figura 5-21: Diagrama de carga real e previsto para 28 de Maio de 2015.	106
Figura 5-22: Evolução da percentagem de erro para 28 de Maio de 2015.	106
Figura 5-23: Diagrama de carga real e previsto para semana 9-15 de Fevereiro de 2015.	107
Figura 5-24: Evolução da percentagem de erro para semana 9-15 de Fevereiro de 2015.	107
Figura 5-25: MAPE para cada dia de semana 9-15 de Fevereiro de 2015.	108
Figura 5-26: Diagrama de carga real e previsto para o mês de Outubro de 2015.	108
Figura 5-27: Evolução da percentagem de erro para o mês de Outubro de 2015.	109
Figura 6-1: Evolução do preço da energia eléctrica do mercado diário para Portugal, dia 21/01/2015. Obtido de (OMIE, 2015).	112
Figura 6-2: Diagrama de carga real e prevista, 2015-10-15, Portugal.	113
Figura 6-3: Evolução de preços médios diários durante o mês de Outubro do ano 2015, Portugal.	114
Figura 6-4: Distribuição de potência produzida por fontes, 2015-10-15, Portugal.	114
Figura 6-5: Composição do vector de entrada final para a previsão da ponta do diagrama de carga para o dia seguinte.	116
Figura 6-6: Previsão de pontas diárias, Março 2015, Lisboa.	117
Figura 6-7: Previsão de pontas diárias, Julho 2015, Porto.	117
Figura 6-8: Previsão de pontas diárias, Dezembro 2015, Évora.	118
Figura 6-9: Previsão mensal de pontas, Outubro 2015, Lisboa.	119
Figura 6-10: Evolução da percentagem de erro relativa à figura 6-9.	119
Figura 6-11: Resultados da previsão para a RNT, Outubro 2015.	120
Figura 6-12: Evolução de percentagem de erro de previsão da figura 6-8.	120
Figura 6-13: Diagrama de pontas diárias de carga do ano 2015, Évora.	121
Figura 7-1: Coincidência das pontas dentro dum intervalo temporal (em tracejado) no dia 1, e não coincidência – no dia 2.	128
Figura 7-2: Comparação dos resultados dos métodos de previsão, em número de coincidências das 100 horas de maior carga face ao real.	129

Figura 7-3: Comparação dos resultados dos métodos de previsão, em nº de coincidências dos 20 dias de maior ponta face ao real.	130
Figura 7-4: Comparação das pontas previstas e reais, caso de estudo da cidade de Évora.....	131
Figura 7-5: Comparação das pontas previstas e reais, caso de estudo da cidade de Lisboa.	132
Figura 7-6: Comparação das pontas previstas e reais, caso de estudo da cidade de Porto.	133
Figura 7-7: Comparação dos períodos críticos resultantes dos métodos de previsão com os resultantes do diagrama real, caso de estudo Évora.....	135
Figura 7-8: Comparação dos períodos críticos resultantes dos métodos de previsão com os resultantes do diagrama real, caso de estudo Lisboa.	136
Figura 7-9: Comparação dos períodos críticos resultantes dos métodos de previsão com os resultantes do diagrama real, caso de estudo Porto.	137
Figura 7-10: Comparação do grau de eficácia dos resultados das previsões, face aos resultados baseados no diagrama real de consumos.	142
Figura 7-11: Comparação do grau de eficácia dos resultados das previsões, face aos resultados baseados no diagrama real de consumos. (Definição dos períodos de ponta crítica conforme projecto-piloto.).....	145

Lista de Tabelas

Tabela 3-1: Os coeficientes de correlação entre a carga e temperatura/humidade, Porto 2014.....	51
Tabela 3-2: Os coeficientes de correlação entre a carga e temperatura/humidade, Portugal 2014..	51
Tabela 3-3: Coeficientes de correlação correspondentes à carga e temperatura média. Lisboa, 2014.	55
Tabela 3-4: Coeficientes de correlação correspondentes à carga e temperatura mínima diária. Lisboa, 2014.	57
Tabela 3-5: Coeficientes de correlação correspondentes à carga e temperatura máxima diária. Lisboa, 2014.	57
Tabela 3-6: Coeficientes de correlação correspondentes à carga e humidade relativa média diária. Lisboa, 2014.	58
Tabela 4-1: Principais coeficientes de autocorrelação identificados nas séries de carga de Lisboa, 2014.....	68
Tabela 4-2: Os intervalos de patamares de ciclo semanal, retirado de (ERSE, 2017).	71
Tabela 4-3: Os intervalos cronológicos de patamares de ciclo diário (segundo o exemplo da figura 4-7).	72
Tabela 5-1: Parâmetros estatísticos para a análise do erro do modelo de previsão.	83
Tabela 5-2: Os valores de MAPE obtidos para a previsão para a hora seguinte.	88
Tabela 5-3: Análise do erro de previsão das subestações do Porto.	90
Tabela 5-4: Análise do erro de previsão das subestações de Évora.....	90
Tabela 5-5: MAPE – previsão do dia seguinte.....	93
Tabela 5-6: Os parâmetros de MAPE para cada tipo de previsão efectuado.	96
Tabela 5-7: Os parâmetros de MAPE para cada tipo de previsão efectuado	97
Tabela 5-8: MAPE, MPE e RMSPE para três casos de estudo.	101
Tabela 5-9: Comparação de indicadores de erro MAPE e RMSPE obtidos com outros modelos de previsão baseados em redes neuronais.	103

Tabela 5-10: Comparação de indicadores de erro MAPE e RMSPE obtidos com outros modelos de previsão diferentes de redes neuronais.	103
Tabela 7-1: Percentagens de coincidências das 100 horas de maior carga prevista com as 100 horas de maior carga real.	127
Tabela 7-2: Períodos associados a cada uma das épocas para determinação dos períodos horários do projeto de introdução de Tarifas Dinâmicas.	133
Tabela 7-3: Simulação de potências médias em horas críticas e não críticas e encargo de potência adicional em horas de ponta crítica no caso de Évora, ano 2015.	140
Tabela 7-4: Simulação de potências médias em horas críticas e não críticas e encargo de potência adicional em horas de ponta crítica no caso de Lisboa, ano 2015.	141
Tabela 7-5: Simulação de potências médias em horas críticas e não críticas e encargo de potência adicional em horas de ponta crítica no caso do Porto, ano 2015.	141
Tabela 7-6: Simulação de potências médias em horas críticas e não críticas e encargo de potência adicional em horas de ponta crítica no caso de Évora, ano 2015. (Definição dos períodos de ponta crítica conforme projecto-piloto).	143
Tabela 7-7: Simulação de potências médias em horas críticas e não críticas e encargo de potência adicional em horas de ponta crítica no caso de Lisboa, ano 2015. (Definição dos períodos de ponta crítica conforme projecto-piloto).	144
Tabela 7-8: Simulação de potências médias em horas críticas e não críticas e encargo de potência adicional em horas de ponta crítica no caso do Porto, ano 2015. (Definição dos períodos de ponta crítica conforme projecto-piloto).	144
Tabela 10-1: Potência média tomada activa recolhida relativa ao quatro transformadores das SE Évora e SE Caeira: as primeiras cinco horas de 1/1/2013.	162
Tabela 10-2: Dados meteorológicos do IPMA, estação de Évora: os primeiros sete dias do ano 2012.	164

Lista de Siglas e Abreviaturas

ANN	<i>Artificial Neural Networks</i>
AT	Alta Tensão
BT	Baixa Tensão
BTE	Baixa Tensão Especial
DC	Diagrama de carga
DSM	<i>Demand Side Management</i>
DSO	<i>Distribution System Operator</i>
ERSE	Entidade Reguladora dos Serviços Energéticos
GA	<i>Genetic Algorithm</i>
IA	Inteligência Artificial
IEEE	<i>Institute of Electrical and Electronics Engineers</i>
MAT	Muito Alta Tensão
MIBEL	Mercado Ibérico de Electricidade
MT	Média Tensão
IPMA	Instituto Português do Mar e da Atmosfera
LTLF	<i>Long-term load forecasting</i>
MAPE	<i>Mean Absolute Percentage Error</i>
MTLF	<i>Medium-term load forecasting</i>
PCD	Padrão de Carga Diário
PRE	Produção em Regime Especial
PT	Posto de Transformação
PTI	Potência Total Instalada
PTT	Potência Total de Transformação
REE	Redes de Energia Eléctrica
RMSE	<i>Root Mean Squared Error</i>

RNA	Rede Neuronal Artificial
RND	Rede Nacional de Distribuição
RNT	Rede Nacional de Transporte
SCADA	<i>Supervising Control and Data Acquisition</i>
SE	Subestação Eléctrica
SEE	Sistemas de Energia Eléctrica
SEP	Sistema Eléctrico Público
SGD	Sistemas de Gestão da Distribuição
STLF	<i>Short-term load forecasting</i>
TP	Transformador de Potência
TSO	<i>Transmission System Operator</i>
VSTLF	<i>Very-short term load forecasting</i>

Introdução

Neste capítulo, descrevem-se de uma forma resumida o enquadramento, a motivação e os objectivos desta dissertação. Colocam-se as questões de investigação com hipóteses de solução das mesmas. Apresenta-se também a metodologia de investigação e a estrutura da tese.

1.1 ENQUADRAMENTO E MOTIVAÇÃO

A previsão de carga de energia eléctrica é uma das tarefas fundamentais para o planeamento, operação e exploração dos Sistemas de Energia Eléctrica (SEE).

A importância da previsão actualmente tem crescido significativamente, devido principalmente ao papel essencial para a gestão e controlo de SEE. Estes sistemas, enquanto estruturas organizadas com vista à produção, transporte, distribuição e abastecimento de energia eléctrica, existem há mais de um século, e, como todos os sectores da economia, têm sido alvo de diversas transformações tecnológicas e organizacionais (Willis & Philipson, 2005).

A partir da década noventa do século passado, a estrutura organizativa do SEE em Portugal tem sido alvo de reconversão, da organização vertical para uma estrutura mais horizontal, com separação de negócios entre diversos agentes. A reestruturação do sector da energia eléctrica veio abrir caminho a que as Redes de Energia Eléctrica (REE) passassem a poder funcionar de forma análoga a outros sectores da economia, na medida em que o acesso livre às REE (Decreto-Lei nº 182/95, de 27 de Julho) permitiu a livre concorrência. Com a desverticalização do sector entre produtores era expectável uma maior eficiência económica e uma eventual redução dos preços da energia eléctrica para o consumidor de uso final (Gomes, 2004).

No novo Sistema Eléctrico Nacional integrado, as actividades de produção e comercialização são exercidas em regime de livre concorrência, mediante a atribuição de licença, e as actividades de transporte e distribuição são exercidas mediante a atribuição de concessões de serviço público (Pereira, 2010).

A partir de Julho de 2007 os mercados eléctricos de Portugal e de Espanha passaram a integrar o Mercado Ibérico de Electricidade (MIBEL). As relações entre as empresas que operam neste novo cenário são mais complexas, do ponto de vista técnico e comercial. Para aumentar a eficiência do sector da distribuição são normalmente desenvolvidas acções de controlo e monitorização e estimação de carga dos sistemas de distribuição, normalmente suportadas em Sistemas de Gestão da Distribuição (SGD) que são concebidos com vários pacotes de aplicações (Wan, 2003). Figura 1-1 ilustra-o na forma de um diagrama.

A previsão de cargas considera-se neste contexto como uma das funções importantes que fornecem informações para aplicações do sistema.

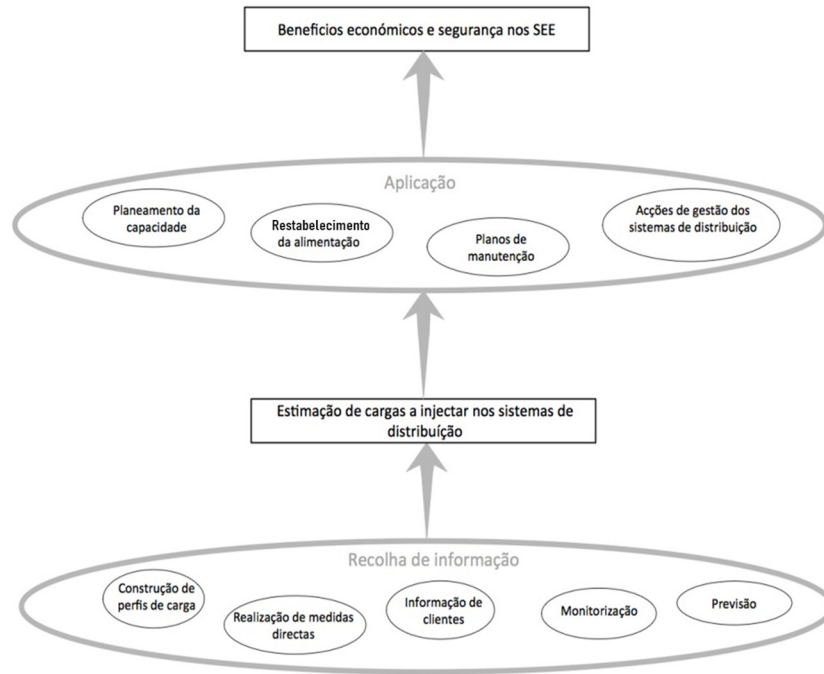


Figura 1-1: As principais funções de Sistemas de Gestão da Distribuição.

As trocas comerciais suportadas na rede eléctrica exigem um maior conhecimento sobre o tipo de consumidores de energia eléctrica e o respectivo padrão de carga diário (PCD), bem como um conhecimento dos valores de consumo com maior detalhe (por exemplo, a ponta do diagrama diário). Assim, a previsão de cargas, torna-se mais complexa fruto de diversos factores endógenos e exógenos, deste modo as metodologias de previsão em diversos horizontes desempenham um papel de relevo (Rahman, 1990).

Neste tipo de ambiente de livre concorrência é fundamental assegurar o alto nível técnico das infra-estruturas das redes de transporte e de distribuição com um elevado nível de fiabilidade e qualidade de serviço (Santos, Previsão de cargas em horizonte de curto-prazo aplicada a subestações de distribuição, 2005).

Em ambiente desverticalizado, o conceito de resiliência torna-se crucial na elaboração das estratégias de estabelecimento e desenvolvimentos dos sistemas de energia projectados para suportar a mais ampla variedade de choques externos. A sociedade actual, baseada nos princípios e leis do mercado, tende a maximizar a

eficiência económica. Tal pode levar a reduzir a resiliência do sistema em relação a uma variedade de eventos, mais ou menos catastróficos. Como é frequentemente discutido no contexto das mudanças climáticas, é crucial considerar o conceito de resiliência no projecto de sistemas e infra-estrutura com o objectivo de evitar vários choques externos que podem ocorrer no futuro (Kishita, et al., 2017).

Na maior parte dos sistemas de energia existentes, as estratégias de desenvolvimento visam alcançar a sustentabilidade ambiental e económica, mas o conceito de resiliência ainda não foi incorporado de forma desejável. Os futuros sistemas de energia resilientes devem fornecer e manter os serviços necessários e suficientes aos clientes, no caso de eventos catastróficos (por exemplo, desastres naturais, erro humano e instabilidade política), que possam provocar o fracasso do sistema energético (Woods, 2015).

A resiliência é definida como a capacidade de um sistema para absorver choques externos e restabelecer-se enquanto se submetem a mudanças para manter essencialmente a mesma função. Diferenciando-se do conceito de sustentabilidade, a ênfase da resiliência é sobre como o sistema responde a perturbações dinâmicas não-lineares. Da definição apresentada resulta a importância da carga do sistema eléctrico e do rigor da sua previsão, sendo a principal função do sistema a alimentação dos consumos de energia eléctrica. Um sistema de energia eléctrica deve ser capaz de atender continuamente à procura de energia eléctrica de forma económica, confiável e em conformidade com critérios pré-estabelecidos para o risco de interrupção. Para que estes objectivos sejam alcançados a operação do sistema deve ser planeada com antecedência. Uma melhor previsão do diagrama de carga desses consumos permitirá planejar as reservas do sistema, linhas e geração, com um nível de confiança mais elevado para fazer face aos eventuais constrangimentos e incidentes que possam ocorrer (Kishita, et al., 2017).

O futuro do SEE está associado à crescente introdução de soluções descentralizadas e flexíveis, conjuntamente com maior ênfase na gestão do lado da procura. Nesse sentido, surge o conceito *Demand Side Management* (DSM), segundo o qual procura-se o aumento da eficiência do SEE através de um papel mais activo dos consumidores de energia eléctrica que têm a possibilidade de regular o seu consumo em função da conveniência do sistema, reduzindo-o às horas de maior carga e aumentando-o nas

horas de vazio. Este comportamento pode ser benéfico para o SEE, não só pela redução do pico da procura, quando se recorre ao parque electroprodutor menos eficiente, mas igualmente pela redução da cava do período de vazio, em situação de elevada produção de energia renovável não controlada. A União Europeia, no âmbito da Directiva 2009/72/EC, já recomendou que os Estados Membros adoptassem mecanismos de aumento da eficiência energética que permitissem uma maior participação dos consumidores na eficiência do sistema, incluindo DSM, designadamente através de tarifas apropriadas (European Parliament, Council of the European Union, 2012).

A participação dos consumidores na gestão da carga do SEE poderá resultar em poupanças para o consumidor final e numa optimização dos recursos das redes e de produção de energia eléctrica para os respectivos agentes. Uma das vantagens de DSM poderá corresponder à diminuição do preço da energia eléctrica às horas de ponta e da volatilidade do mercado de energia. Esse efeito pode ser conseguido à custa de uma menor pressão exercida sobre o mercado, criando condições para um menor recurso às centrais menos eficientes e, conseqüentemente, para uma redução do preço da energia. Por outro lado, a deslocação dos consumos para as horas de vazio, em situação de excesso de produção renovável, poderá contribuir para a valorização, no mercado, da energia produzida nessas condições, habitualmente transaccionada a valor zero, ou próximo de zero. O benefício para os consumidores finais, em particular para os consumidores domésticos, resulta da redução da diferença para a tarifa subsidiada a que esta energia é paga aos produtores e que é reflectida na tarifa de uso do sistema como Custos de política energética e de Interesse Económico Geral (CIEG).

Um segundo aspecto que poderá permitir o aumento da eficiência global do SEE é a redução da necessidade de contratação dos chamados serviços de sistema, que visam assegurar um nível de reserva de potência na rede para fazer face a ocorrências de exploração. Actuando ao nível do consumo, a dimensão dessa reserva poderia ser reduzida.

Por último, não menos importante, uma maior participação dos consumidores na gestão da carga do SEE, através da redução do consumo em alturas de maior congestionamento das redes eléctricas, para além da redução das perdas de energia, que

por si só já constitui um benefício, poderá evitar o recurso a soluções mais dispendiosas, permitindo aos operadores optimizarem o investimento no reforço nas suas redes.

A participação dos consumidores no processo de DSM não se circunscreve aos grandes consumidores empresariais, com sofisticados sistemas de gestão de energia. O desenvolvimento das *smart grids* (redes inteligentes), incluindo o *smart metering*, e a massificação da domótica, da produção distribuída e dos veículos eléctricos constituem a base tecnológica para a concretização de medidas eficazes de DSM por parte de um conjunto alargado de pequenos consumidores (figura 1-2).

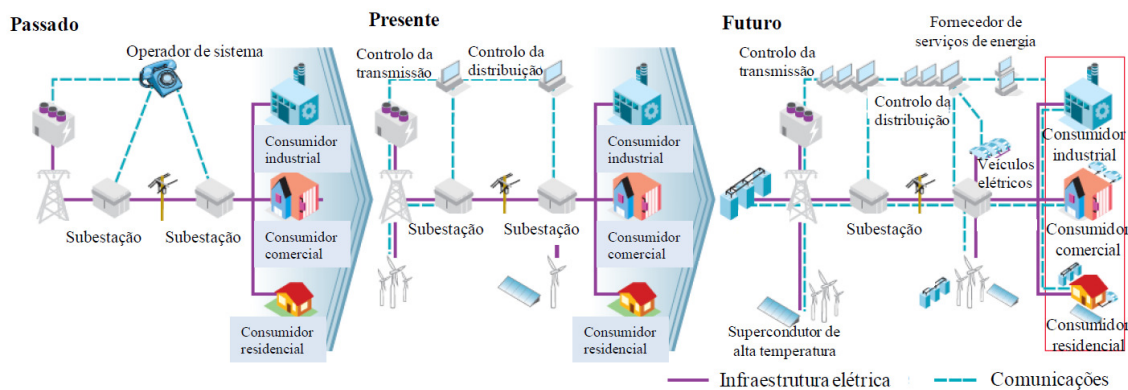


Figura 1-2: Sistemas de Energia Eléctrica: do passado até futuro (*smart grids*).
Obtido de (Fagundes, 2013).

Com o evoluir das tecnologias de comunicação e de informação, as *smart grids* surgem como uma visão integrada para o futuro das redes eléctricas bidireccionais que progressivamente darão resposta aos desafios de estabilidade das redes de energia eléctrica e às constantes oscilações entre a oferta e procura de energia. A visão *smart grids* preconiza um novo paradigma de operação, que envolve a passagem da concepção de produção centralizada de electricidade, transporte e distribuição até aos consumidores, para um modelo em que existe uma forte componente de produção distribuída pelos vários níveis das redes e que, coexistindo com a produção tradicional de base, formam um sistema activo e integrado em todos níveis de exploração das redes (EDP Distribuição, 2015).

A eficácia das acções de DSM está fortemente dependente do rigor da previsão dos diagramas de carga de curto prazo. O efeito dessas acções é tanto mais benéfico, quanto

o seu impacto no diagrama de carga for nos momentos das cargas mais elevadas da rede (pontas). Ao pretender atingir um maior rigor na previsão do diagrama de carga de curto prazo, incluindo as pontas, o presente trabalho adquire maior importância.

1.2 QUESTÕES DE INVESTIGAÇÃO

1.2.1 INTRODUÇÃO AO PROBLEMA DE PREVISÃO DA CARGA ELÉCTRICA

Tendo por base o conhecimento empírico dos DC's e das zonas previsíveis de maior consumo e a esperada evolução dos valores do diagrama de carga, os operadores de sistemas de energia conseguem, de uma forma baseada no conhecimento, planear o *mix* de produção para o dia seguinte. Este tipo de decisões é estabelecido coordenando os planos de produção hídrica e térmica, pelo operador de sistema. A regulação dos grupos geradores e o arranque dos grupos de reserva, sempre que envolva decisões de nível de operação das centrais térmicas, resulta também na diminuição das emissões de CO₂ e numa maior eficiência do *mix* de produção.

No actual contexto de maior peso da produção de energia a partir de fontes renováveis intermitentes, tais como eólica e solar, no balanço energético aumenta o risco de segurança de abastecimento do sistema. Torna-se por isso necessário de boas previsões para um correcto dimensionamento das reservas de produção do sistema mobilizáveis em curto espaço de tempo.

Recordando as noções básicas da exploração de sistemas eléctricos, o diagrama de carga representa a variação da potência activa em função do tempo. Para comparação da carga real e prevista traçam-se ambas no plano P, t (onde P é a potência activa em MW e t é o tempo em horas). A figura 1-3 apresenta, como exemplo, o diagrama de carga do dia 16 de Janeiro de 2012 na Rede Eléctrica Nacional (REN), sem considerar a interligação das redes entre Portugal e Espanha (Bernardino, 2013). Os valores reais são em cor azul, e os previstos – em cinzento.




Figura 1-3: Potência real e prevista num Diagrama de Carga diário.

Os diagramas de carga constroem-se na base dos valores da potência média tomada (muitas vezes designados também por procura), registados pelo SCADA (*Supervisory Control And Data Acquisition*). A potência média tomada é um valor recolhido por cada intervalo de 15 minutos, que resulta da integração da potência instantânea e cujo resultado é dividido pelo intervalo de tempo (Santos, Previsão de cargas em horizonte de curto-prazo aplicada a subestações de distribuição, 2005). A Figura 1-4 apresenta os valores instantâneos de potência e a potência média tomada, que se representa por um valor constante no intervalo de tempo de 15 minutos.




Figura 1-4: Exemplo de potência instantânea e potência média tomada (baseado no (Kersting, 2007)).

À potência máxima do diagrama de carga chama-se ponta, e à mínima – vazio. No DC diário na Figura 1-3 as pontas registaram-se por volta das 10 horas da manhã, e por

volta das 20 horas, à noite. Os vazios ocorreram na madrugada e na hora do almoço. Em geral, as horas exactas de registo da potência máxima e mínima dependem do tipo de carga: industrial, comércio, residencial entre outras (Farias, 2008).

Existem também dois parâmetros que nos permitem uma análise relativa à assimetria do DC, bem como outro tipo de informação relevante, nomeadamente factor de carga e factor de vazio. O factor de carga é o quociente entre a potência média e máxima, do diagrama de carga, e dá uma ideia da forma mais ou menos cheia do diagrama. Convém o factor de carga ser o mais elevado possível para obter o melhor aproveitamento da rede (o factor de carga óptimo é igual à unidade). O factor de vazio é relação entre a potência mínima e máxima, do diagrama de carga, e dá uma ideia da maior ou menor depressão que o vazio das horas de menor consumo (noite) introduz no diagrama e de que maneira a rede é aproveitada durante este período.

1.2.2 PROBLEMAS DE INVESTIGAÇÃO

Com esta tese procura-se encontrar resposta para um conjunto de questões, nomeadamente:

Q1. Será possível obter o diagrama de carga de energia eléctrica, em cada ponto injectador da rede eléctrica nacional, bem como a respectiva ponta (potência máxima do diagrama de carga), em diversos horizontes temporais: hora seguinte e dia seguinte?

Q2. Como se pode incorporar no modelo predictor a informação de natureza climática?

Q3. Como lidar com os erros de previsão da carga eléctrica? Como minimizá-los?

Q4. Como é que o modelo predictor pode ser útil na implementação de um novo sistema de tarifas dinâmicas e consequente desenvolvimento das medidas de *Demand Side Management* (DSM) associadas?

1.2.3 HIPÓTESES

Como hipóteses de solução das questões apresentadas, destacam-se as seguintes:

H1. Existe conhecimento dos diagramas de carga nos pontos injectores da rede de transporte na rede de distribuição de energia eléctrica em média tensão, para caracterização do consumo de energia eléctrica (histórico de cargas).

H2. Existe conhecimento da interdependência entre as variáveis endógenas e exógenas. As variáveis endógenas são as cargas eléctricas (potências activas) e as exógenas são os parâmetros climáticos (temperatura do ar, humidade do ar, velocidade do vento etc.).

H3. O modelo previsor de cargas eléctricas pode ser baseado nos métodos estatísticos tradicionais ou nos métodos de inteligência artificial, com rigorosa avaliação do erro entre o diagrama de carga real e o previsto.

H4. Em Portugal iniciou-se um projecto-piloto de sistema de tarifas dinâmicas promovido pela Entidade Reguladora dos Serviços Energéticos (ERSE). O rigor da previsão dos diagramas de carga de curto prazo, especialmente nos períodos de ponta crítica, pode ter impacto significativo na eficácia desse sistema.

A investigação desenvolvida neste trabalho, sob o ponto de vista da abordagem do problema, é qualitativa-quantitativa. Mas no que diz respeito aos seus objectivos, é exploratória, pois envolve a construção e validação de um modelo de previsão, e assim, o resultado da investigação estará sujeito a avaliações e comparações.

1.3 METODOLOGIA DE INVESTIGAÇÃO

Nesta secção são apresentadas as principais contribuições esperadas, seguidas do plano de trabalho detalhado e da metodologia de validação.

1.3.1 CONTRIBUIÇÃO

No que concerne aos contributos desta tese, são esperados os seguintes:

- Desenvolvimento e implementação de um algoritmo baseado num ou em vários métodos de previsão de carga eléctrica, destinado a prever o consumo de curto-prazo (24 horas, 48 horas, uma semana), incluindo a ponta.

- Estabelecimento de uma análise aprofundada sobre as interdependências entre as variáveis endógenas (potência activa - consumo) e exógenas (climáticas).
- Obtenção de diagramas de carga previstos nos pontos injectores da rede de transporte na rede de distribuição de energia eléctrica sob tensão 60 kV, de acordo com a metodologia proposta.
- Produção de previsões suficientemente robustas consoante os horizontes temporais, bem como nos diversos barramentos da rede.
- Realização de testes com o objectivo de validação do desempenho do algoritmo.
- Avaliação dos erros de previsão (em conformidade com o horizonte de previsão).
- Estabelecimento de critérios de DSM (*Demand Side Management*) – Gestão da Procura, que possam constituir uma mais-valia para os operadores da Rede de Distribuição.
- Aumento da eficácia das medidas de DSM consubstanciada em sistemas tarifários dinâmicos, incentivando o alisamento dos diagramas de carga das redes.

1.3.2 PLANO DE TRABALHO

As diversas fases do trabalho estruturam-se da seguinte forma:

1. Formulação das perguntas de pesquisa. Levantamento do estado actual dos conhecimentos nas diversas aproximações mais recentes ao problema de estimação/reconhecimento de padrões de energia eléctrica.
2. Análise detalhada dos objectivos, limitações e condicionantes das diversas aproximações, numa perspectiva comparada.
3. Elaboração de perspectiva de síntese sobre vias de abordagem metodológica alternativas, com equacionamento do nível de integração de objectivos, bem como eventuais potenciais e dificuldades de implementação.
4. Definição detalhada de uma proposta metodológica própria.
5. Implementação do suporte de experimentação sobre a metodologia especificada.

6. Análise de um ou mais casos de estudo. Aplicação da metodologia de análise considerada aos pontos injectores reais (zonas sul, centro e norte de Portugal).

7. Escrita da tese.

O plano de trabalho e programação segue o método clássico de investigação, como representado na figura 1-5.

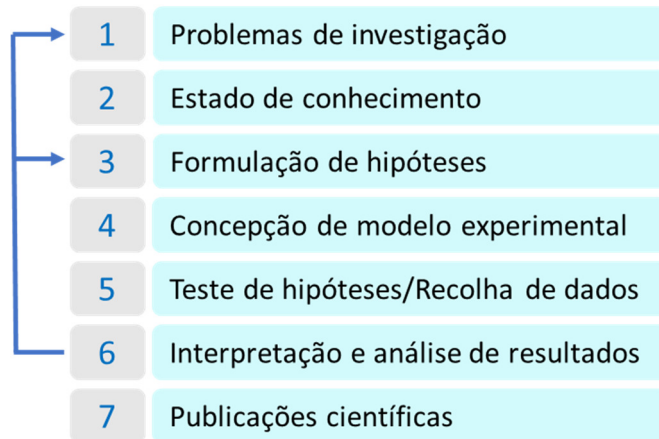


Figura 1-5: Os métodos clássicos de investigação. Adaptado de (Camarinha-Matos, 2010).

Nesse diagrama o “Teste das hipóteses” corresponde à Implementação do suporte de experimentação sobre a metodologia especificada, i.e., vão ser simulados vários modelos de diagramas de cargas da rede em média tensão.

No bloco “Interpretação e análise de resultados” são obtidos os resultados durante as simulações conforme os algoritmos propostos. Esses resultados são confrontados com os realmente verificados nas subestações de média tensão em Portugal.

Os resultados são satisfatórios? Se não, voltar ao passo 3, construir outras hipóteses de modelos de carga, ou melhorar os já feitos; se sim, ir ao passo 7 – publicação de resultados.

1.4 METODOLOGIA DE VALIDAÇÃO

Com os dados recolhidos através do sistema SCADA das diversas subestações AT/MT optou-se por construir uma base estatística (histórico) que foi utilizada pelo modelo de previsão e constituiu o suporte de alimentação.

O modelo final tem que ser avaliado pela qualidade dos seus resultados o que implica o menor valor de erro possível. Em primeira análise, o erro calcula-se como o valor da percentagem média absoluta do erro - MAPE (*Mean Absolute Percentage Error*). Segundo o estudo comparativo elaborado por (Hippert, Pedreira, & Sousa, 2001) este parâmetro de aferição é o mais divulgado na bibliografia sobre os métodos de previsão de carga eléctrica. De qualquer modo, os erros máximos admissíveis, tendo em conta a utilização do modelo e tendo em atenção tanto a bibliografia estudada como outros trabalhos na área, poderão oscilar até erros com um limite de 10%. Este valor poderá ser considerado para outros como um valor elevado, mas tendo em conta a aplicação e o horizonte previsto para a previsão este erro é aceitável para os operadores da gestão da rede de distribuição. Este erro pode ser mais significativo com o alargamento do horizonte de previsão nomeadamente de uma a duas semanas.

Para a análise mais profunda do desempenho do modelo de previsão recorreu-se a um conjunto de indicadores estatísticos (DeLurgio, 1998) entre os quais destacam-se os seguintes:

- O valor do erro médio (*mean error*);
- O desvio médio absoluto (*mean absolute deviation*);
- A soma dos erros quadráticos (*sum of squared errors*);
- A média dos erros quadráticos (*mean squared errors*).

O caso real de estudo constitui uma mais valia significativa pois permitiria estabelecer as previsões com base em dados reais. Este tipo de trabalho vai assim ser testado em condições reais de condução (*offline*).

Como metodologias de previsão poderão ser utilizados sistemas baseados no conhecimento pois permitem lidar de melhor forma com a incerteza bem como com a não linearidade dos dados em causa (DeLurgio, 1998). Normalmente essas metodologias definem-se como as de Inteligência Artificial, entre quais destacam-se os seguintes: Redes Neurais Artificiais, Lógica Fuzzy, Algoritmos Genéticos etc. Muitas publicações na área de previsão de carga eléctrica de curto-prazo nas redes de média tensão assentam nas metodologias baseadas em Redes Neurais Artificiais (Hippert, Pedreira, & Sousa, 2001), (Santos, Martins, & Pires, Designing the input vector to

ANN-based models for short-term load forecast in electricity distribution systems, 2007), (Rodygina & Rodygin, 2016).

A presente tese, desenvolve uma metodologia de previsão do diagrama de carga para o dia seguinte, utilizando as vantagens das técnicas baseados nas redes neuronais artificiais, combinadas com uma nova abordagem de composição do vector de entrada dessas redes. A novidade introduzida no vector de entrada que, para além de variáveis de potência activa, escolhidas de acordo com as técnicas de correlação com variáveis meteorológicas e de autocorrelação, inclui o conceito de patamar e a introdução de um sinal aleatório, que visa estimular o modelo regressivo.

Com esta nova composição no vector de entrada, esta metodologia de previsão do diagrama de carga para a hora seguinte e para o dia seguinte pretende aumentar o rigor da previsão, reduzindo o seu erro, tanto na componente temporal do diagrama (carga em função da hora), como na componente da ponta (valor máximo do diagrama). Desta forma, conhecendo melhor o diagrama de carga esperado, são criadas as condições de resposta mais eficaz às perturbações, contribuindo para o aumento da resiliência da operação do sistema eléctrico.

Como será visto nos capítulos posteriores, os resultados obtidos com a simulação dos casos reais de redes de distribuição de energia eléctrica em Portugal, utilizando o modelo proposto, confirmam o aumento do rigor da previsão de carga eléctrica e podem ser úteis na implementação do novo sistema tarifário nacional.

1.5 ESTRUTURA DA TESE

O texto desta tese está dividido em oito capítulos, descritos a seguir.

No Capítulo 1, o actual, descreve-se o enquadramento, onde se descrevem de uma forma resumida sobre o Sistema Eléctrico Nacional, a motivação e as questões de investigação desta tese. Descrevem-se também as acções desenvolvidas para atingir os objectivos pretendidos neste trabalho.

No Capítulo 2, “O Estado da Arte”, analisam-se os principais métodos de previsão de carga eléctrica com apresentação de um conjunto de referências bibliográficas sobre esta área. Descrevem-se também os horizontes de previsão.

No Capítulo 3, “Recolha de informação para os casos de estudo”, são analisados os dados recolhidos nas subestações da rede de distribuição e os dados climáticos de Portugal continental.

No Capítulo 4, “Modelo de Previsão Proposto”, descreve-se a metodologia das Redes Neurais Artificiais (RNA) que, em combinação com os padrões de carga em patamares e injeção do sinal aleatório, foi adoptada para o modelo predictor neste trabalho.

No Capítulo 5, “Implementação do modelo e os resultados obtidos”, consideram-se vários casos de estudo para a previsão de carga eléctrica nas redes de distribuição. Analisam-se os resultados obtidos usando os critérios estatísticos de avaliação de previsões deste tipo.

No Capítulo 6, “Previsão das pontas do diagrama de carga de uma rede num ambiente de tarifas dinâmicas”, faz-se análise de resultados de previsão de potência de ponta e a o seu impacto num sistema tarifário baseado em tarifas dinâmicas.

No Capítulo 7, “Previsão das cargas em ambiente de gestão da procura”, descrevem-se os sistemas emergentes de gestão da procura e faz-se a análise da aplicação dos métodos de previsão de cargas em ambiente de tarifas dinâmicas.

Finalmente no Capítulo 8, “Conclusões e Perspectivas de Trabalhos Futuros”, são enumeradas as conclusões retiradas com a elaboração da dissertação. São apresentadas as publicações científicas referentes a este trabalho de investigação. São também descritos os trabalhos futuros que podem ser desenvolvidos no âmbito deste tema.

O estado da arte

Neste capítulo descrevem-se os horizontes de previsão. Analisam-se os principais métodos de previsão de carga eléctrica (os estatísticos e os baseados em Inteligência Artificial) e apresenta-se um conjunto de referências bibliográficas sobre esta área.

2.1 INTRODUÇÃO

Em todas abordagens metodológicas de previsão, existem características semelhantes. Em geral, os métodos de previsão assumem que as mesmas causas que estiveram presentes no modelo da carga, permanecerão no futuro, ou seja, o comportamento do passado é a base para inferências sobre o comportamento do futuro. Os resultados exactos nunca são atingidos. O erro de previsão será tanto maior quanto maior for o horizonte de previsão. Uma das causas, são os factores aleatórios que não são fáceis de incorporar nos modelos. Se o erro da previsão aumentar de uma forma significativa, ter-se-á seguramente de trocar de método, ou um outro que se revele mais adequado (Dias, 2010).

O modelo de previsão da carga eléctrica, de acordo com (Tubino, 2007), pode ser dividido em cinco etapas:

1. Objectivo do Modelo
2. Recolha e Análise dos Dados
3. Selecção da Técnica de Previsão
4. Obtenção das Previsões
5. Monitorização do Modelo

Numa primeira etapa define-se a razão pela qual será necessário prever, o produto que será previsto e o grau de confiabilidade desta previsão. Em seguida deverá ser estabelecida a recolha e a análise dos dados históricos do consumo por forma a identificar qual a metodologia de previsão mais adequada, para o caso de estudo. Os resultados da previsão devem ser comparados com os dados reais por forma a calcular o erro obtido e de modo a aferir a precisão do modelo.

2.2 OS HORIZONTES DE PREVISÃO

De acordo com (Gross & Galiana, 1987) os horizontes de previsão de carga eléctrica classificam-se em muito curto, curto, médio e longo prazo.

A previsão de muito curto-prazo (*Very-short term load forecasting* - VSTLF) restringe-se ao horizonte de alguns minutos até uma hora. É uma previsão em tempo

real, que se utiliza para a regulação de tensão e frequência, para o planeamento da produção e para a análise de contingências em tempo real.

A previsão de curto-prazo (*Short-term load forecasting* - STLF) possui o horizonte de previsão até trinta dias. Estima-se a ponta diária e a carga para todas as horas do dia. O STLF ajuda no planeamento de despacho económico e transferência de carga. É importante para as várias acções de operadores de redes eléctricas: reconfiguração das redes, agendamento de acções de manutenção, controlo de tensão, correcção do factor de potência.

A previsão de médio-prazo (*Medium-term load forecasting* - MTLF) conta com o horizonte temporal nos próximos meses até um ano. Serve para planeamento das capacidades de produção, transporte e distribuição, calendarização dos processos de manutenção e armazenamento de combustível.

E, por fim, a previsão de longo-prazo (*Long-term load forecasting* - LTLF) preocupa-se com intervalos superiores a um ano, indo a um horizonte de dez e mais anos. Juntamente com MTLF é ideal para o planeamento de Sistemas de Energia Eléctrica quando os dados diários e semanais não são considerados. A previsão de médio e longo prazo contribui na tomada de decisões tanto sobre a expansão da rede eléctrica, como na nova localização de subestações de distribuição.

A classificação destes horizontes não é única. Por exemplo, previsões consideradas de médio prazo para algumas empresas de energia eléctrica podem ser consideradas de longo prazo para outras. De forma análoga, previsões para intervalos de alguns minutos até uma hora adiante (muito curto prazo) são consideradas para algumas empresas como previsões de curto prazo (Ferreira V. , 2005).

Visto que esta tese aborda o horizonte de previsão de uma hora e de um dia seguinte, onde as abordagens metodológicas encontradas são bastante abundantes, a revisão bibliográfica destas está apresentada num subcapítulo em separado, que se descreve a seguir.

2.3 MÉTODOS DE PREVISÃO DA CARGA

A previsão de cargas é uma área de intensa pesquisa e conta com uma vasta literatura

técnica, descrevendo uma variedade de métodos (Hippert, Pedreira, & Sousa, 2001), (Khatoon, Ibraheem, Singh, & Priti, 2014), (Zor, Timur, & Teke, 2017). Tal facto reflecte a busca pelos operadores de SEE e investigadores nesta área de métodos capazes de gerar previsões precisas e que permitam um melhor uso dos recursos disponíveis, optimizando a gestão e a operação de SEE.

Em geral, os métodos de previsão de cargas eléctricas podem ser divididos em estatísticos tradicionais e nos baseados em Inteligência Artificial (IA).

Cronologicamente, na evolução dos métodos de previsão observa-se um avanço significativo. Historicamente foram utilizados os métodos estatísticos, surgindo, na década de sessenta, os métodos essencialmente baseados em aproximações regressivas. Na expectativa de ultrapassar as desvantagens das metodologias tradicionais de previsão, nas décadas de oitenta e princípios de noventa do século passado, surgem as metodologias baseadas em técnicas de Inteligência Artificial.

Entre os métodos estatísticos podemos citar regressão linear múltipla, análise de séries temporais, alisamento exponencial etc. (Khatoon, Ibraheem, Singh, & Priti, 2014). Um dos métodos largamente difundidos é o ARIMA de Box and Jenkins (Gross & Galiana, 1987), (Paretkar, Mili, Centeno, Kaiyan, & Miller, 2010).

Entre os métodos na área de IA, encontram-se as redes neuronais artificiais, sistemas especialistas, lógica fuzzy, algoritmos genéticos, mapas auto organizativos, máquinas de vector suporte, enxame de partículas etc. (Fallah, Deo, Shojafar, Conti, & Shamshirband, 2018), (Zor, Timur, & Teke, 2017), (Abdurahmanov, Volodin, Zybin, & Ryabchenko, 2016). Muitos destes métodos assentam numa pré-escolha das variáveis de entrada, considerando as diferentes correlações entre variáveis exógenas e endógenas (Kaytez, Taplamacioglu, Cam, & Hardalac, 2015).

Também vêm sendo desenvolvidos métodos chamados híbridos, que consistem em combinação de dois ou mais métodos diferentes de previsão. Por exemplo, utilizam-se frequentemente técnicas de optimização da estrutura da rede neuronal através de algoritmos genéticos (Zor, Timur, & Teke, 2017).

Os métodos estatísticos têm vantagem de serem técnicas matemáticas já bem desenvolvidas e estudadas, mas dependem de uma modelação matemática complexa. O modelo regressivo, por exemplo, considera a carga como uma combinação linear de

funções tais como sinusóides, exponenciais, etc. (Guirelli, 2006). Consiste na determinação da curva que melhor se ajusta aos dados históricos da carga, utilizando o método de mínimos quadrados. Os modelos baseados em séries temporais incorporam na previsão não só os dados históricos, mas também outros factores, tais como temperatura ambiente, sazonalidade e efeitos aleatórios.

Os métodos baseados na Inteligência Artificial permitem lidar da melhor forma com a incerteza, bem como com as funções não lineares. O desenvolvimento desses métodos possibilita determinar o comportamento de um sistema baseado nas variáveis endógenas e exógenas, e em particular, no seu histórico. Deste modo, passou-se a dispor de métodos de interpolação de sistemas que não dependiam de um modelo matemático complexo ou do conhecimento profundo do sistema. As técnicas de IA ajudam a descobrir (aprender) padrões de comportamento num conjunto de dados e, posteriormente, a aplicar o conhecimento adquirido em novas amostras. Mas estes métodos apresentam problemas específicos. Assim a sua codificação, nem sempre é fácil de determinar, uma vez que se torna fundamental encontrar as variáveis mais significativas para o modelo de previsão (Zor, Timur, & Teke, 2017), (Fallah, Deo, Shojafar, Conti, & Shamshirband, 2018).

A previsão baseada na teoria de Inteligência Artificial, mais propriamente nas Redes Neurais Artificiais (RNA), foi amplamente aceite no mundo científico e da engenharia, tornando-se uma das técnicas mais difundidas para a previsão de carga. A vantagem das RNA reside no facto de que o conhecimento é extraído da base de dados sem a necessidade do conhecimento prévio do modelo de evolução da carga eléctrica. Este conhecimento surge em função de estímulos, i.e., entrada/saída de variáveis de carga, adequadamente aplicados à rede neuronal, constituindo a fase de treino da rede (Sousa, Neves, & Jorge, 2012). Existem diversas publicações científicas que provam a qualidade e robustez das previsões baseadas em redes neuronais (Hippert, Pedreira, & Sousa, 2001), (Park, Lee, Son, & Ahn, 2017). Uma vez que a metodologia de previsão baseada nessas redes tem um papel importante neste trabalho, reserva-se para o Capítulo 4 uma descrição mais detalhada das mesmas.

Ainda dentro das metodologias de previsão encontra-se o método de *Data Mining* (Mineração de Dados) que constitui uma área interdisciplinar de análise, revelando o

seu potencial no processo de busca de leis empíricas e apoiando-se na estatística aplicada, reconhecimento de padrões, teoria de bases de dados e Inteligência Artificial. Este tipo de abordagem é diferente dos métodos estatísticos usuais. Nos métodos de *Data Mining* ocorre a integração da teoria e da heurística com concentração num único processo de análise de dados. Essa análise inclui o tratamento de grandes bases de dados, aprendizagem, integração, avaliação e visualização de resultados (Abdurahmanov, Volodin, Zybin, & Ryabchenko, 2016).

Data Mining é uma das etapas do amplo conceito *Knowledge-Discovery in Databases (KDD)*, que abrange a preparação dos dados (aquisição dos dados, limpeza, filtragem e pré-processamento), a interpretação e a avaliação do modelo descoberto com possibilidade de retorno a algum passo anterior (Rosário, 2014). Várias etapas de *KDD* podem ser observadas na figura 2-1, onde podem ser aplicadas diversas técnicas.



Figura 2-1: Esquema geral de etapas de *Knowledge-Discovery in Databases*, obtido de (Rosário, 2014).

Depois da definição do conhecimento que se deseja adquirir, retira-se um conjunto de dados e selecciona-se o conjunto de variáveis necessárias. Em seguida é estabelecido o pré-processamento dos dados, que inclui a remoção de dados inválidos e do ruído, a estimação de dados em falta, etc. Os dados transformados submetem-se à mineração de dados, cujas funções são classificação, sumarização, regressão etc. Depois, na avaliação dos resultados os padrões encontrados são interpretados, contribuindo para os conhecimentos úteis e interessantes nas aplicações práticas (Fayyad, Piatetsky-Shapiro, & Smyth, 1996).

Apresenta-se a seguir a descrição sucinta de algumas fontes bibliográficas analisadas que serviram como ponto de partida na escolha do método de previsão de carga eléctrica. Nos trabalhos apresentados nas publicações citadas encontram-se diversas metodologias cujo objectivo é a resolução de problemas específicos de determinados países ou regiões (Kaytez, Taplamacioglu, Cam, & Hardalac, 2015). O limite e a adaptabilidade de cada um dos métodos dependem da diversidade e profundidade temporal da informação recolhida, do horizonte de previsão, bem como do clima da região geográfica e do grau de interdependência entre o consumo e as variáveis exógenas (Santos, Previsão de cargas em horizonte de curto-prazo aplicada a subestações de distribuição, 2005). A análise de publicações na área de previsão seguiu, quando possível, o tipo de metodologia utilizada, horizonte de previsão e medida do erro de previsão.

Os (Moghran & Rahman, 1989) desenvolveram e compararam cinco modelos de previsão de diagrama de carga diária, nomeadamente: Regressão Linear Múltipla, Alisamento Exponencial, Séries Temporais, Sistema Especialista e Modelo de Espaço de Estado. Apresentando várias vantagens e desvantagens de cada modelo, os autores chegam à conclusão que é muito difícil escolher o modelo perfeito cujos critérios de qualidade dependem das próprias séries temporais. A série temporal é composta pelos valores de potência (carga eléctrica) registados no passado.

Em (Papalexopoulos & Hesterberg, 1990) é apresentado um modelo de previsão de carga a curto prazo baseado em Regressão Linear Múltipla com abordagem de dia de semana, feriados, eventos especiais e temperatura de ar. Os resultados de previsão foram estimados através do método de mínimos quadrados ponderados e ficaram superiores aos obtidos pelo modelo implantado naquela altura pela empresa *Pacific Gas and Electric Company, EUA*.

No estudo de (Chen, Tzeng, & Hwang, 1996) a previsão a curto-prazo foi realizada com as redes neuronais que foram aplicadas aos três tipos de carga: residencial, comercial e industrial. Consideraram-se os dados de potência nas subestações da empresa Taipower e também os da temperatura e da humidade. O erro médio relativo percentual não ultrapassou 2,87%.

Em (Trudnowski, Mcreynolds, & Johnson, 2001) os autores aplicaram o filtro de

Kalman para elaborar o modelo baseado no espaço de estados para previsão de carga a curto e muito curto prazo. Para testar o modelo foram usados os dados duma empresa de transporte de energia eléctrica no Noroeste dos EUA – *Bonneville Power Administration*, obtendo bons resultados.

O problema da previsão de cargas eléctricas a curto-prazo (24 horas à frente) no trabalho de (Altran, 2005) foi resolvido com ajuda do algoritmo *backpropagation* numa rede neuronal multicamadas *feedforward*. Foram utilizadas diferentes funções de activação de base radial: Gaussiana, Multiquadrática Recíproca e Recíproca Inversa, Secante Hiperbólica e função Sigmóide. Foram consideradas três aplicações com os arquivos de dados históricos de uma companhia do sector eléctrico. Utilizou-se um vector de entrada composto pelo dia da semana e hora do dia, codificados na representação binária, mais a carga horária corrente e os valores de cargas considerando-se três horas anteriores. Verificou-se a precisão calculando o erro percentual absoluto médio (MAPE) e o erro máximo da previsão diária. Os valores mínimos obtidos de erros foram iguais à 1,03% e 2,57%, respectivamente.

O modelo de previsão de carga eléctrica desenvolvido por (Sousa, Barros, & Miranda, 2006) baseia-se no método de amortecimento exponencial de Holt-Winters multiplicativo, com dois ciclos: o diário e o semanal. Os dados utilizados são referentes a uma concessionária de energia eléctrica da região sudeste do Brasil. A previsão foi feita para cada 15 minutos, sendo o horizonte de previsão de 15 dias. O erro médio percentual absoluto (MAPE) variava entre 1,59% e 3,84%.

Os métodos utilizados no estudo do (Guirelli, 2006) são as redes neurais artificiais e a lógica fuzzy. Como ferramenta de filtragem de dados usou-se a transformada Wavelet. A Wavelet serviu para decompor a curva de carga, executar a filtragem, mas ao invés de recompor o sinal, treinar as redes neurais com as componentes.

No trabalho (Figueiredo, Santos, & Cechin, 2009) é apresentado o desenvolvimento de dois modelos neuronais para longo e curto prazo. Também se apresenta a integração em nível topológico desses modelos. As variáveis foram seleccionadas pelo uso do método *Forward Selection*. Foram realizados os ensaios com três cenários, ou regiões, com comportamento de carga predominante diferentes: região com carga industrial, região com carga residencial e região com carga equilibrada (ou mista). Para analisar os

resultados foram utilizados métodos de análise quantitativa – *Root Mean Squared Error (RMSE)* e qualitativa – análise gráfica dos padrões previstos através de sobreposição das suas curvas.

(Araújo, Vitti, Lotufo, & Lopes, 2010) implementaram um programa de previsão para um horizonte de até 14 dias utilizando Rede Neuronal Artificial Feedforward com treinamento por Levenberg-Marquardt e por Rede Neuronal de Base Radial. O erro máximo para estes dois tipos de redes foi de 5,24% e de 6,20%, respectivamente.

Na publicação (Lopes, 2012) foi apresentado um modelo híbrido utilizando as vantagens dos modelos ARIMA de Box & Jenkins e das RNA com treino realizado pelo algoritmo de Levenberg-Marquardt. Previsão feita no período de 24 em 24 horas. Os dados históricos (reais) foram tratados no *software R* utilizando a biblioteca *forecast*, a fim de obter o melhor modelo ARIMA da série. Foram utilizadas 4 entradas da rede neuronal, que possui 3 camadas, sendo que a camada de entrada é composta por 13 neurónios, a camada intermediária por 27 e a camada de saída por 1 neurónio. As restantes entradas da rede neuronal são compostas por dados binários correspondentes aos feriados, dias da semana e horas de dia. A saída da rede neural faz a previsão do erro futuro das 24 horas que se deseja prever. O modelo proposto apresenta bons resultados, garantindo uma boa previsão, com MAPE inferiores a 1% e erros máximos inferiores a 1,1%.

A metodologia proposta no trabalho de (Pessanha & Justino, 2013) foi concebida para fornecer previsões de carga até 48 horas seguintes, com resolução temporal de 10, 15, 30 e 60 minutos. Três módulos distintos foram utilizados: 1. Lógica *fuzzy* – para gerar a previsão do perfil da curva de carga para as próximas 48 horas; 2. Rede neuronal artificial polinomial tipo GMDH (*Group Method of Data Handling*) - para prever a procura mínima e a ponta diárias; 3. Interpolação por partes com funções *splines*, cuja finalidade consiste em obter previsões com maior resolução temporal a partir das previsões horárias. Usou-se a série de carga no período de 1 de Agosto de 2005 até 28 de Fevereiro de 2010. Estatísticas de desempenho do modelo: erro médio relativo percentual – 2,02%, desvio padrão do erro - 1,77%.

Em (Yang, Chen, Yachen, Li, & Li, 2016) foi utilizada a composição de três técnicas: RNA com algoritmo *Backpropagation*, *Adaptive Network Based Fuzzy*

Inference System (ANFIS) e o modelo *Seasonal Auto Regressive Integrated Moving Average (SARIMA)*, onde os resultados da previsão do método combinado mostraram-se melhores do que os obtidos pelos três métodos individualmente. O método combinado (híbrido) foi capaz de reduzir os erros e melhorar a precisão dos valores previstos face aos valores reais, de forma eficaz.

2.4 CONCLUSÕES

Existem diversas abordagens metodológicas que são usadas para a previsão da potência eléctrica, entre estas, as metodologias de regressão baseadas em RNA vem se apresentando como uma das mais utilizadas na previsão (Kaytez, Taplamacioglu, Cam, & Hardalac, 2015).

A análise dos métodos mais recentes permite afirmar que não existe um método universal de previsão e que possa satisfazer todos os requisitos dos utilizadores. Cada abordagem metodológica tem os seus limites de aplicação, por vezes é necessário recorrer a combinações de diferentes metodologias (Abdurahmanov, Volodin, Zybin, & Ryabchenko, 2016).

Recolha de informação para os casos de estudo

Neste capítulo são descritas as principais características das redes de energia eléctrica e das subestações dos casos de estudos e analisados os dados recolhidos. Foram também analisados os dados meteorológicos de Portugal continental.

3.1 INTRODUÇÃO

A Rede Nacional de Transporte (RNT) é operada pela REN que desempenha o papel de TSO (*Transport System Operator*). A RNT de acordo com a definição da ERSE assegura o escoamento da energia eléctrica produzida nas centrais electroprodutoras até às redes de distribuição as quais conduzem essa energia até às instalações dos consumidores finais (ERSE, 2016).

A rede de transporte é constituída quase exclusivamente por linhas aéreas, nos níveis de tensão de 400 kV, 220 kV e 150 kV. A rede de transporte engloba ainda troços em cabo subterrâneo, explorados a 220 kV e 150 kV, nomeadamente na região da Grande Lisboa.

As redes de distribuição, por sua vez, são constituídas por linhas aéreas e por cabos subterrâneos, de alta tensão (60 kV), de média tensão, fundamentalmente 30 kV, 15 kV e 10 kV, e de baixa tensão (400/230 V), existindo ainda uma linha explorada a 130 kV, no Norte de Portugal, integradas na rede de distribuição. Existem ainda redes de distribuição em Média Tensão, de pequena dimensão, a 6 kV. A empresa responsável pela gestão, exploração e manutenção dessas redes é EDP Distribuição (DSO - *Distribution System Operator* em Portugal).

Além das referidas linhas e cabos, as redes de distribuição são ainda constituídas por subestações, postos de seccionamento, postos de transformação e equipamentos acessórios ligados à sua exploração, como aparelhos de corte instalados nos apoios da rede aérea de Média Tensão. Fazem ainda parte das redes de distribuição as instalações de iluminação pública e as ligações a instalações consumidoras e a centros electroprodutores (ERSE, 2016).

A rede de distribuição em Alta Tensão (AT), 60 kV, é responsável por elevados fluxos de potência que abrange várias subestações AT/MT, podendo atingir-se numa linha de AT valores acima das 70 ou 80 MVA, em situações de ponta (potência máxima), em zonas de maior densidade de cargas (urbanas ou industriais). Assim sendo, tornam-se importantes alguns aspectos na estrutura dessa rede, como a possibilidade de configuração de socorro (redes malhadas, ou bi-alimentadas).

Os casos de estudo assentam no desenvolvimento do modelo de previsão da carga em subestações da rede transporte/distribuição. Foram utilizadas as séries temporais de dados de carga directamente recolhidas do sistema de telecontagem da EDP Distribuição. Foram seleccionadas as áreas urbanas de três cidades do país: Lisboa (a capital), Porto (a segunda maior cidade) e Évora (uma cidade do Sul). Estas zonas urbanas foram escolhidas dado que a carga ali concentrada é praticamente isolada, não dependendo de alterações topológicas frequentes que ocorrem na exploração das redes de Média Tensão.

No processo de exploração de uma rede de distribuição ocorre, por vezes, a necessidade de alterar a configuração topológica da rede para atender a avarias e substituir a alimentação que estava a ser assegurada pela linha que avariou, por uma linha de recurso, que pode ter alimentação de outra subestação. A necessidade de reconfiguração também ocorre para execução de trabalhos programados de manutenção, ou de expansão das redes, quando é necessário colocar uma linha fora de serviço para se realizar a intervenção. Alterar a configuração topológica da rede MT significa alterar a alimentação das cargas, que pode passar para outra subestação.

Para a avaliação de métodos de previsão de cargas, de alguma forma sempre baseados num período de observação histórica, é importante excluir o ruído causado pela instabilidade do conjunto de cargas. Uma das formas de o conseguir é o de considerar para análise redes, conjuntos de subestações, ou barramentos, que não tenham muitas interligações e, por esse motivo, as transferências de cargas para fora, ou de dentro, desse conjunto não sejam significativas. É o caso das redes escolhidas. Por exemplo, a rede de 15 kV da cidade de Évora, alimentada pelo conjunto de duas subestações: Évora e Caeira. Apenas existe uma interligação muito fraca com a subestação de Cerâmica que não tem expressão no conjunto da carga. Ocorrem frequentes reconfigurações (transferências de carga) entre estas duas subestações, mas como a previsão do diagrama de carga é efectuada para o conjunto da rede 15 kV alimentada pelas duas subestações, a influência das transferências de carga entre as duas subestações é anulada.

Pretende-se realizar a previsão do diagrama de cargas devido a factores exógenos à rede, como a sazonalidade, os ciclos diário e semanal da actividade humana, o clima e

outros, que não dependem da gestão da rede. Note-se que a informação de consumos histórica disponível para a previsão de cargas é ao nível dos transformadores das subestações. Na cidade do Porto, a rede 15 kV não tem praticamente interligações com as redes dos concelhos vizinhos, alimentados por outras subestações. Esta situação deve-se ao facto de historicamente a rede da cidade do Porto ter sido gerida autonomamente pelos serviços municipalizados do concelho e só mais recentemente, ter sido integrada na rede de distribuição do continente. Na cidade de Lisboa existem interligações com as redes dos concelhos limítrofes, havendo mesmo subestações na periferia que alimentam consumos nesses concelhos. Dada a dimensão da cidade, essas interligações e as transferências de carga que daí resultam não são significativas, pelo que se espera não interfiram no trabalho.

Este estudo destina-se a avaliar as propriedades do algoritmo criado, embora as zonas possam não corresponder à totalidade da carga de um injector da rede de transporte.

A cidade de Évora foi também seleccionada no contexto do desenvolvimento de um projecto de redes inteligentes, levado a efeito nesta cidade. Trata-se de um projecto-piloto realizado pela EDP Distribuição, denominado *InovGrid*. A figura 3-1 apresenta a arquitectura geral do *InovGrid* focada no cliente e numa infra-estrutura integrada do sector eléctrico nacional.

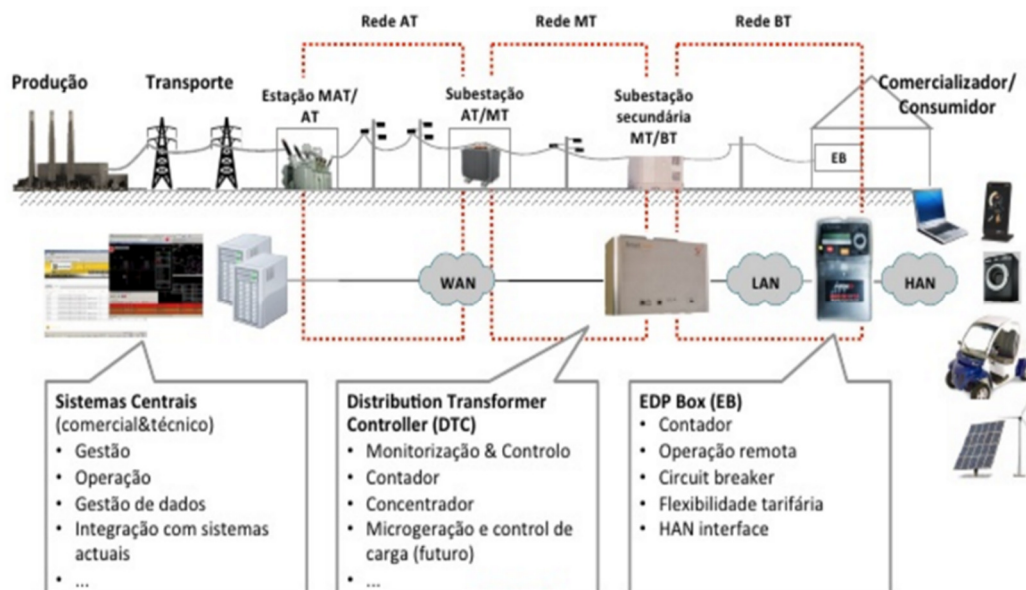


Figura 3-1: Arquitectura do *InovGrid*, obtido de (Ferreira P. , 2012).

Évora tem dado prioridade a projectos de cidades inteligentes, sustentáveis e inclusivos que contribuem para alcançar os objectivos da *Strategy Europe 2020* (European Commission, 2018). O projecto *InovGrid* visa avançar para um sistema de distribuição inteligente de energia eléctrica, focado na telegestão de energia, que revoluciona as redes e seu estilo de interacção entre consumidor e produtor de energia.

Esta mudança foi acompanhada por uma renovação tecnológica e organizacional da operação do sistema de distribuição e relacionamento com as partes interessadas, com base numa infra-estrutura que visa responder às necessidades decorrentes de eficiência energética, comando e controlo remoto, geração distribuída e microgeração e assumir actividades de controlo activo das redes inteligentes.

Esta mudança está associada à instalação de novos equipamentos de medição. No final de 2010, cerca de 30 mil clientes de baixa tensão (doméstico, pequeno comércio e indústria), cobrindo todo o município de Évora, estavam ligados a este sistema eléctrico integrado e inteligente.

As séries temporais do consumo de energia eléctrica obtidas pelo sistema de telemetria *InovGrid* vão compor uma base de dados essencial para o desenvolvimento de aplicações de previsão de carga com maior detalhe ao nível dos pontos de consumo. Os modelos de previsão, como o desenvolvido neste trabalho, poderão vir a usar esses dados.

A figura 3-2 ilustra o mapa de Portugal com a topologia das redes de Muito Alta Tensão (400, 220 e 150 kV). Os pontos negros no mapa representam os pontos injectores da rede de transporte na rede de distribuição de energia eléctrica que são as subestações de Muito Alta Tensão/Alta Tensão (MAT/AT): 400/60 kV, 220/60 kV e 150/60 kV. Há na totalidade 65 (2018) subestações MAT/AT da Rede Nacional de Transporte. A seguir a energia eléctrica é entregue à Rede de Distribuição, onde se segue a transformação Alta Tensão/Média Tensão (AT/MT): 60/30 kV, 60/15 kV e 60/10 kV nas subestações AT/MT localizadas nos principais centros de consumo.

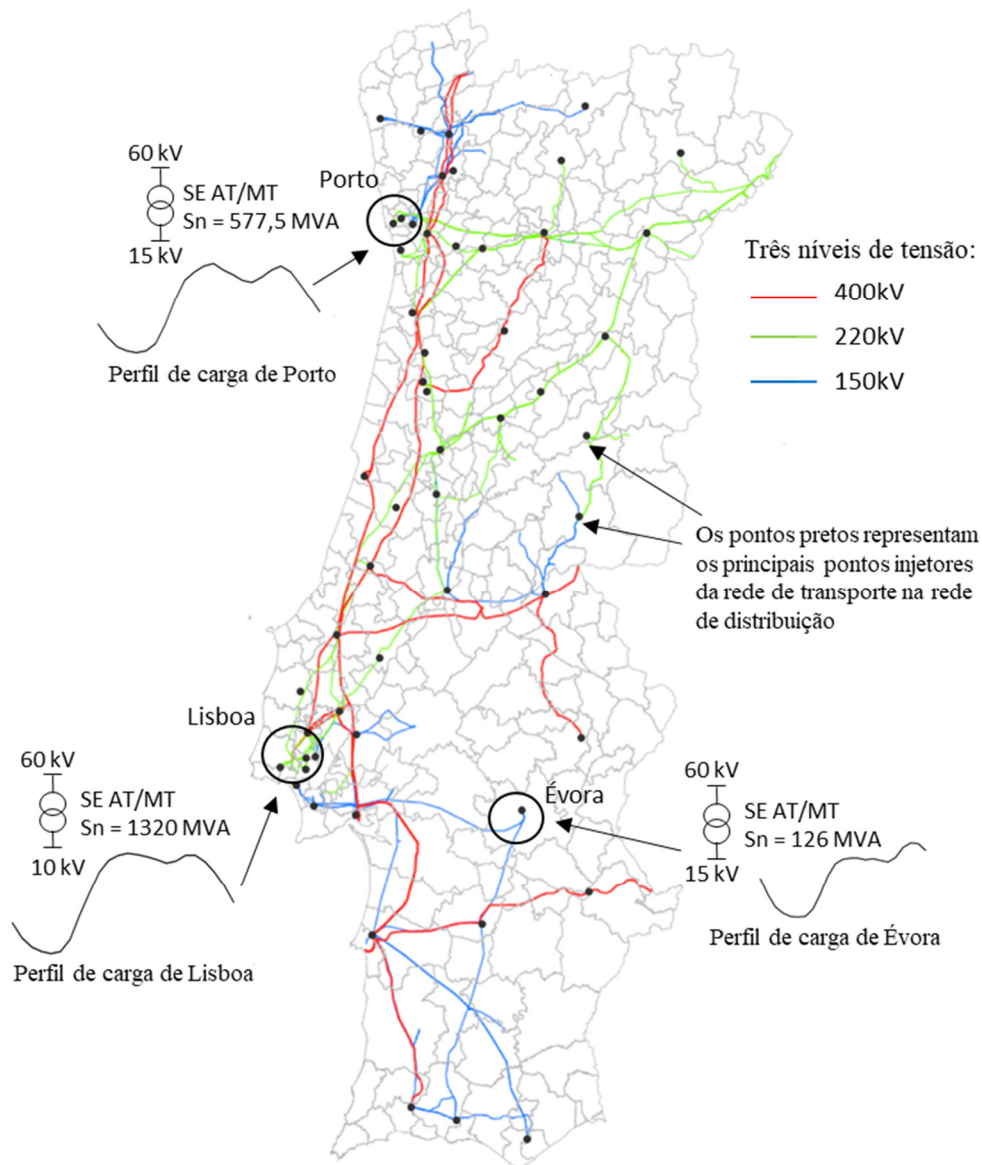


Figura 3-2: Mapa de Portugal, incluindo as redes MAT, as cidades em estudo com os perfis de carga e os principais pontos injectores da rede de transporte na rede de distribuição de energia eléctrica (60kV).

Estão também marcados com os círculos as zonas onde se encontram as subestações de abastecimento de energia eléctrica das cidades de Lisboa, Porto e Évora com os respectivos perfis simbólicos de carga. A potência total instalada nas subestações (as que foram analisadas nesta tese) de Lisboa é 1320 MVA, no Porto, 577,5 MVA e em Évora, 126 MVA. Entre os sectores de consumo, em Lisboa prevalecem os tipos residencial e serviços, nas cidades do Porto e de Évora maioria do consumo é do tipo residencial, serviços e indústria.

3.2 DESCRIÇÃO DE SUBESTAÇÕES USADAS PARA OS CASOS DE ESTUDO

3.2.1 ÉVORA

A rede de distribuição em MT, estabelecida a partir da saída da subestação AT/MT da Rede Nacional de Distribuição (RND), destina-se alimentar os postos de transformação MT/BT. Na Figura 3-3 a rede de transporte em MAT 150 kV representa-se em cor azul, a rede de distribuição em AT 60 kV – preto, as redes de distribuição em MT 30 kV e 15 kV – vermelho e verde, respectivamente.

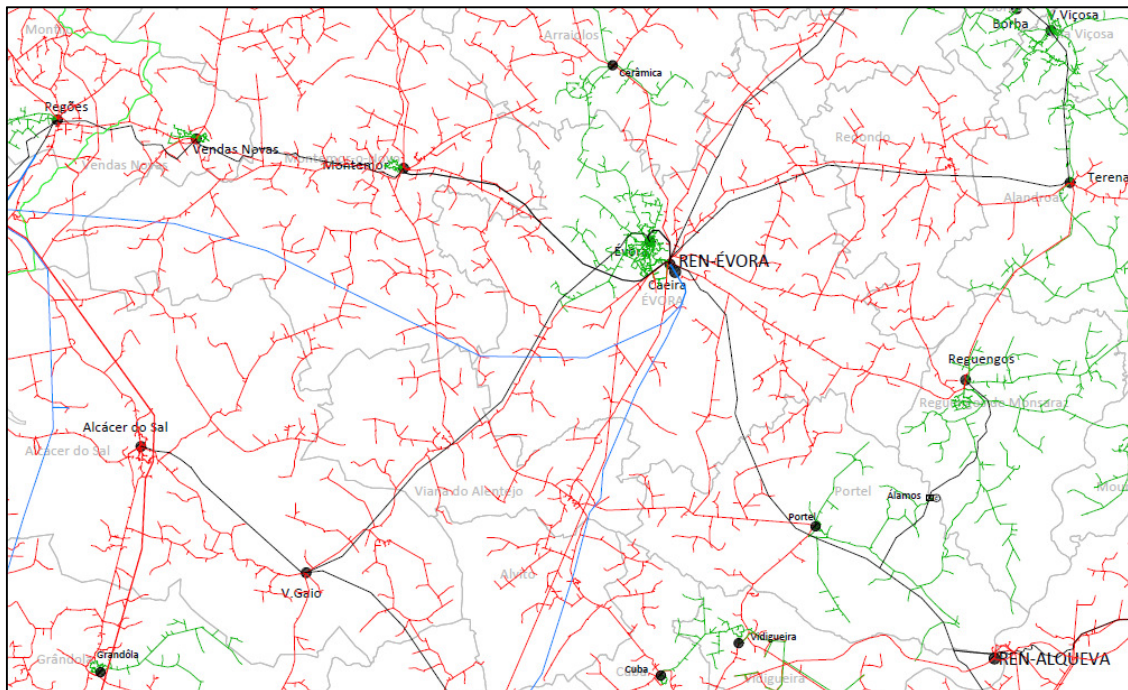


Figura 3-3: Aspecto topológico das redes de 150, 60, 30 e 15 kV na zona da cidade de Évora e arredores.

A Figura 3-4 mostra o *zoom* das referidas redes que abastecem a cidade de Évora.




Figura 3-4: As redes que alimentam a cidade de Évora, fragmento ampliado.

Nos postos de transformação a tensão diminui de média para baixa MT/BT – 15/0,4 kV. Estes postos de transformação, públicos e privados, encontram-se espalhados por toda a cidade. As tensões indicadas atrás são tensões compostas.

Como já foi referido antes, a zona urbana da cidade de Évora é alimentada em Média Tensão, 15 kV, por duas subestações eléctricas de distribuição ligadas à subestação REN de Évora: SE de Évora e SE de Caeira. A Figura 3-5 apresenta as referidas subestações e a rede de distribuição 15 kV, que foi o objecto do primeiro caso de estudo.

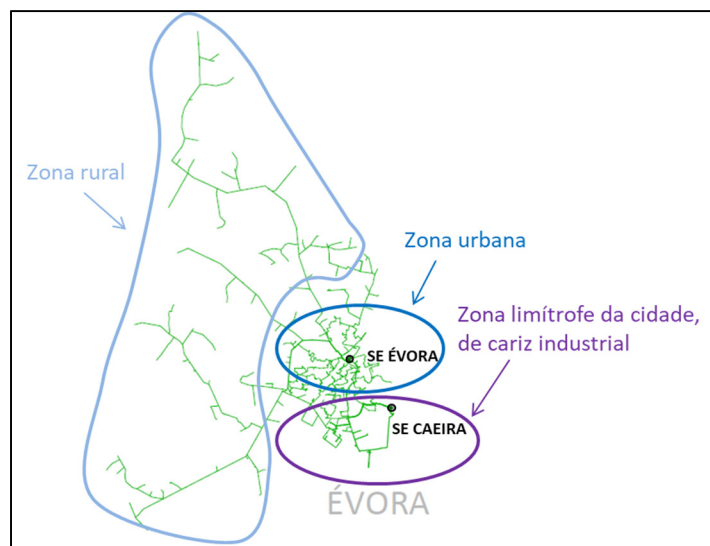


Figura 3-5: Topologia da rede MT 15 kV que alimenta a cidade de Évora.

Nestas subestações estão instalados os transformadores AT/MT: dois de 60/15 kV na SE Évora e dois de 60/30/15 kV – na SE Caeira (Figura 3-6).

A potência total instalada (PTI) nestas subestações é igual a 126 MVA. A SE de Évora possui metade da PTI, partilhada entre dois transformadores de 31,5 MVA cada. Esta subestação encontra-se situada numa zona urbana. A SE de Caeira possui igualmente dois transformadores de potência, de 31,5 MVA cada e está situada na zona limítrofe da cidade, de cariz industrial.

Entre os sectores de consumo de cidade de Évora prevalecem o doméstico, serviços e indústria.

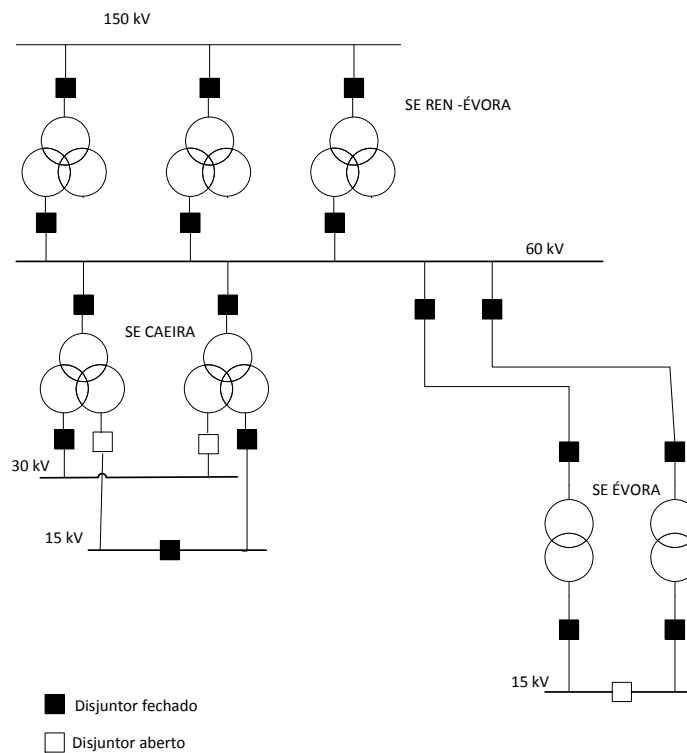


Figura 3-6: Esquema unifilar de SEs de abastecimento de energia eléctrica à cidade de Évora.

A previsão é efectuada para os consumos no conjunto dos barramentos 15 kV das subestações Évora e Caeira.

Entre os sectores de consumo de cidade de Évora prevalecem o doméstico, serviços e indústria.

Os dados que fazem parte do registo das variáveis endógenas do algoritmo da previsão (potência activa, em kW) foram recolhidos nos enrolamentos de 15 kV de cada transformador, através do sistema de telecontagem de energia, relativos aos anos 2013-2015. No Anexo 1 encontra-se um exemplo dos dados recolhidos, relativos aos quatro transformadores, dois da SE Évora e dois da SE Caeira. São os valores da potência média tomada activa, recolhidos de 15 em 15 minutos, durante as primeiras cinco horas do dia 1 de Janeiro de 2013.

Os diagramas de carga representados nas figuras 3-7, 3-8 e 3-9 foram construídos com base nos dados de potência activa, registados pelo sistema de Telecontagem de EDP Distribuição no ano 2013. O sistema de aquisição de dados SCADA regista a potência média tomada que é igual à potência média da potência instantânea durante um intervalo de tempo de 15 minutos. Para calcular a energia eléctrica consumida durante este período de tempo basta multiplicar o tempo (em horas, é igual à 1/4 de hora) pela potência média tomada (em MW), sendo assim o resultado expresso em MWh.




Figura 3-7: Diagrama de carga de uma semana. 9 – 15 de Dezembro, Évora.

Como se vê na figura 3-7, durante a semana (9 - 15 de Dezembro de 2013) observa-se constância nos dias de trabalho e descida no fim-de-semana. A periodicidade semanal no exemplo de duas semanas (7 – 20 de Janeiro de 2013) observa-se na figura 3-8.




Figura 3-8: Diagrama de carga de duas semanas. 7 – 20 de Janeiro, Évora.

Periodicidade anual depende da zona geográfica de país. A região de Norte é caracterizada pelo maior consumo de energia no Inverno (normalmente com ponta na semana anterior ao Natal, ou na 1ª semana de Janeiro) e menor consumo nos meses do Verão. Mas no Sul já não acontece assim: nos meses quentes o consumo de energia eléctrica também é elevado devido ao funcionamento de equipamentos de ar condicionado. A figura 3-9 mostra que o consumo de Évora está elevado tanto no Inverno como nalguns meses de Verão por causa de necessidade de ligação de aparelhos de aquecimento e arrefecimento, respectivamente.




Figura 3-9: Diagrama de carga anual, Évora.

De acordo com a figura 3-10 é notória uma redução de consumo no Verão (4 - 10 de Agosto) em comparação com o Inverno (6 -12 de Janeiro), os dados referem-se ao ano 2014. Observa-se também o menor consumo no fim da semana, devido ao tradicional abrandamento das actividades económicas. O impacto do aquecimento doméstico do Inverno foi maior, em Évora, em 2013 e 2014. Nota-se um aumento do consumo em Julho (figura 3-9) que pode ser justificado pelo aumento da actividade turística no Verão, ou por um tempo demasiado quente. O impacto consistente do turismo no aumento de consumo em Évora é mais recente (anos 2016 e 2017).




Figura 3-10: Diagrama de carga semanal de Inverno e de Verão, Évora.

O tipo de consumidores (indústria, comércio, doméstico) também fortemente influencia o comportamento de diagramas de carga.

3.2.2 PORTO

O segundo caso de estudo refere-se a abastecimento de energia eléctrica à cidade do Porto. O sistema de abastecimento de energia eléctrica nesta zona é assegurado por oito subestações de 60/15 kV conectados a três subestações da REN de 220/60 kV (o diagrama unifilar é representado na Fig. 3-11). A estrutura da rede AT é essencialmente malhada, possuindo as subestações andares AT ligados a dois ou mais circuitos subterrâneos. No entanto, nota-se já a existência de uma subestação, a SE LAPA, que foi a última a ser construída e que se encontra ligada com o esquema de bloco cabo – transformador, sem andar AT. A protecção de cada transformador actua no disjuntor do

respectivo painel no ponto injector, a SE REN PRELADA. Ver-se-á mais à frente que esta configuração é comum na rede da cidade de Lisboa.

A potência total instalada de 60/15 kV é 577,5 MVA, cada subestação tem dois ou três transformadores com cerca de 30 MVA cada. Os principais sectores de consumo de energia no Porto são os domésticos, serviços e alguma indústria.

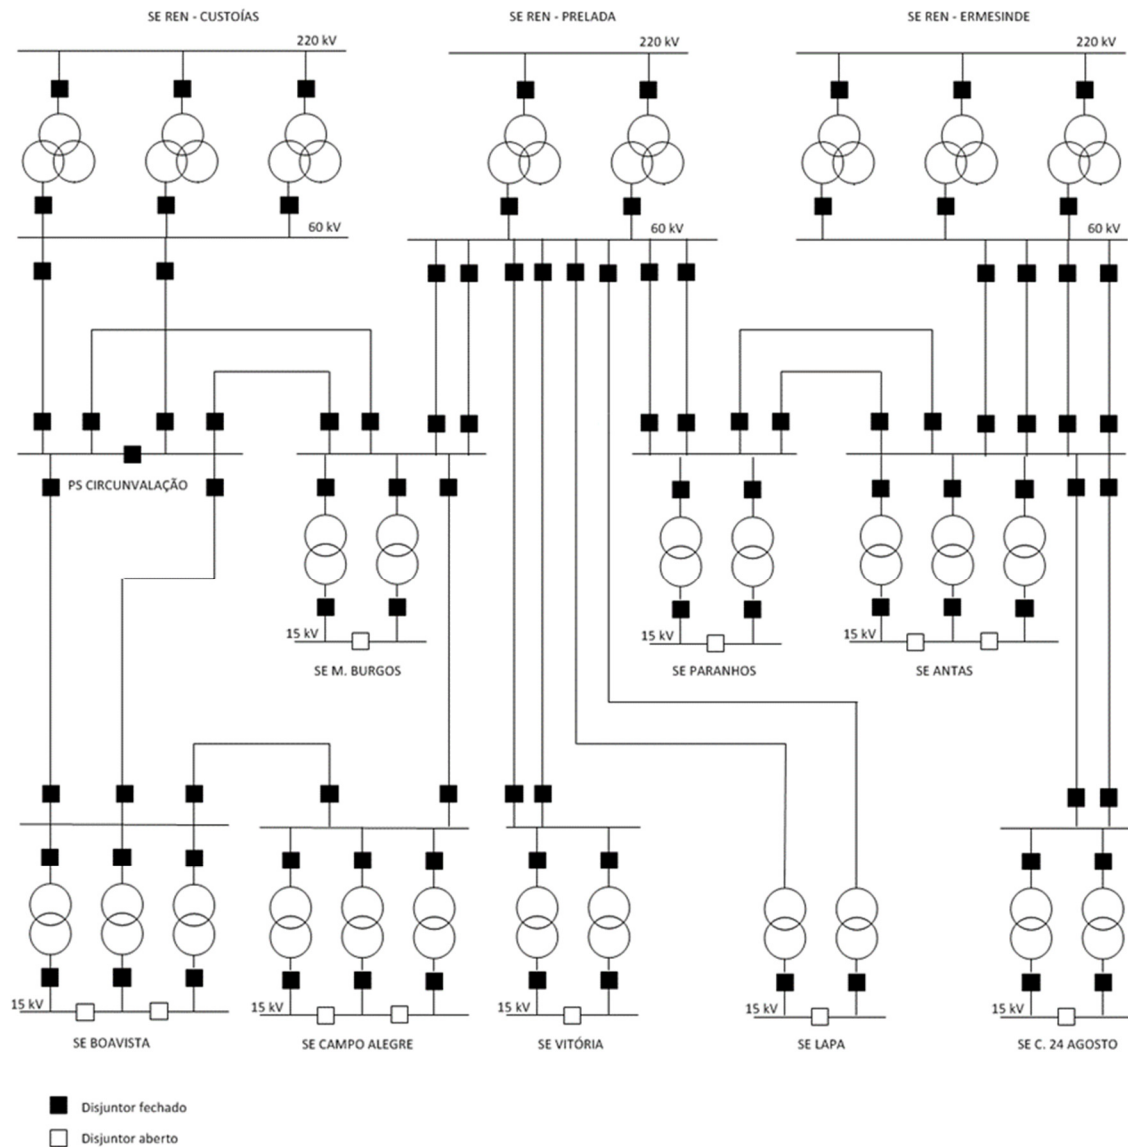


Figura 3-11: Esquema unifilar de SEs de abastecimento de energia eléctrica à cidade do Porto.

A previsão foi realizada no conjunto dos barramentos 15 kV das subestações indicadas no esquema da figura 3-11.

Da mesma forma que para a cidade de Évora, foram construídos também os diagramas de carga para a cidade de Porto.

O diagrama de carga ilustrado pela figura 3-12 representa o comportamento cíclico semanal com a ocorrência de feriados: Sexta-Feira Santa e Páscoa. O feriado na 6ª Feira deu origem a um período de redução da actividade económica mais alargado. A forma atípica do diagrama de carga depende da composição dos consumos. Nota-se o carácter predominante residencial e industrial desta cidade. Verifica-se uma redução da ponta na 6ª Feira, embora a forma do diagrama manteve-se.




Figura 3-12: Diagrama de carga de uma semana de Primavera, 14-20 de Abril de 2014, Porto.

Para comparação, representa-se na figura 3-13 o diagrama de carga de uma semana típica no início de Setembro, do dia 1 ao 7. Nota-se que a ponta de 2ª Feira é mais elevada de entre os dias úteis, provavelmente devido ao arranque da actividade industrial e comercial. Também se observa uma diminuição da ponta no Domingo que pode ser explicado pelo abrandamento comum das actividades económicas neste dia de semana.




Figura 3-13: Diagrama de carga de semana de 1 – 7 de Setembro de 2014, Porto.

A forma e os valores numéricos do diagrama de carga variam conforme as estações do ano (figura 3-14). Observa-se uma redução de consumo da época fria para a época quente, com a redução acentuada na altura de férias de Verão – mês de Agosto.




Figura 3-14: Diagrama de carga do ano 2014, Porto.

3.2.3 LISBOA

A zona de abastecimento da cidade de Lisboa é o terceiro caso de estudo. Há cinco subestações primárias de 220/60kV operadas pela REN que alimentam as redes eléctricas de Lisboa: Sacavém, Alto de São João, Carriche, Sete Rios e Zambujal. Em Lisboa os principais sectores de consumo de energia são os domésticos, serviços e comércio.

As subestações da zona de abastecimento eléctrico da cidade de Lisboa em comparação com as das cidades de Évora e Porto são muito mais numerosas, o que pode ser observado no esquema simplificado (figura 3-15) e no esquema unifilar (figura 3-16).

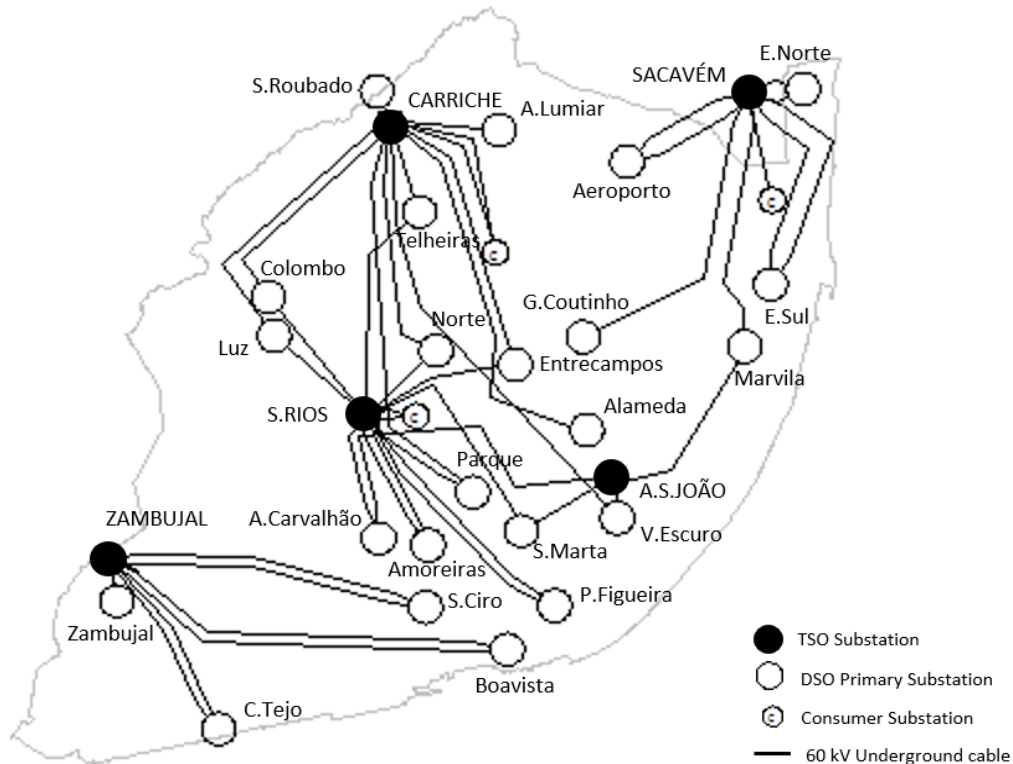


Figura 3-15: Esquema simplificado das subestações e linhas de alta tensão do abastecimento de energia eléctrica da cidade de Lisboa.

A rede AT que liga as subestações na cidade de Lisboa é exclusivamente subterrânea. As subestações AT/MT têm geralmente dois transformadores 60/10 kV, ligados ao ponto injector por dois circuitos, pelo esquema cabo – transformador.

Nestas subestações o equipamento AT é reduzido ao mínimo e a protecção do transformador de potência actua sobre o disjuntor do painel respectivo, no posto de corte e seccionamento (PS) situado a montante.

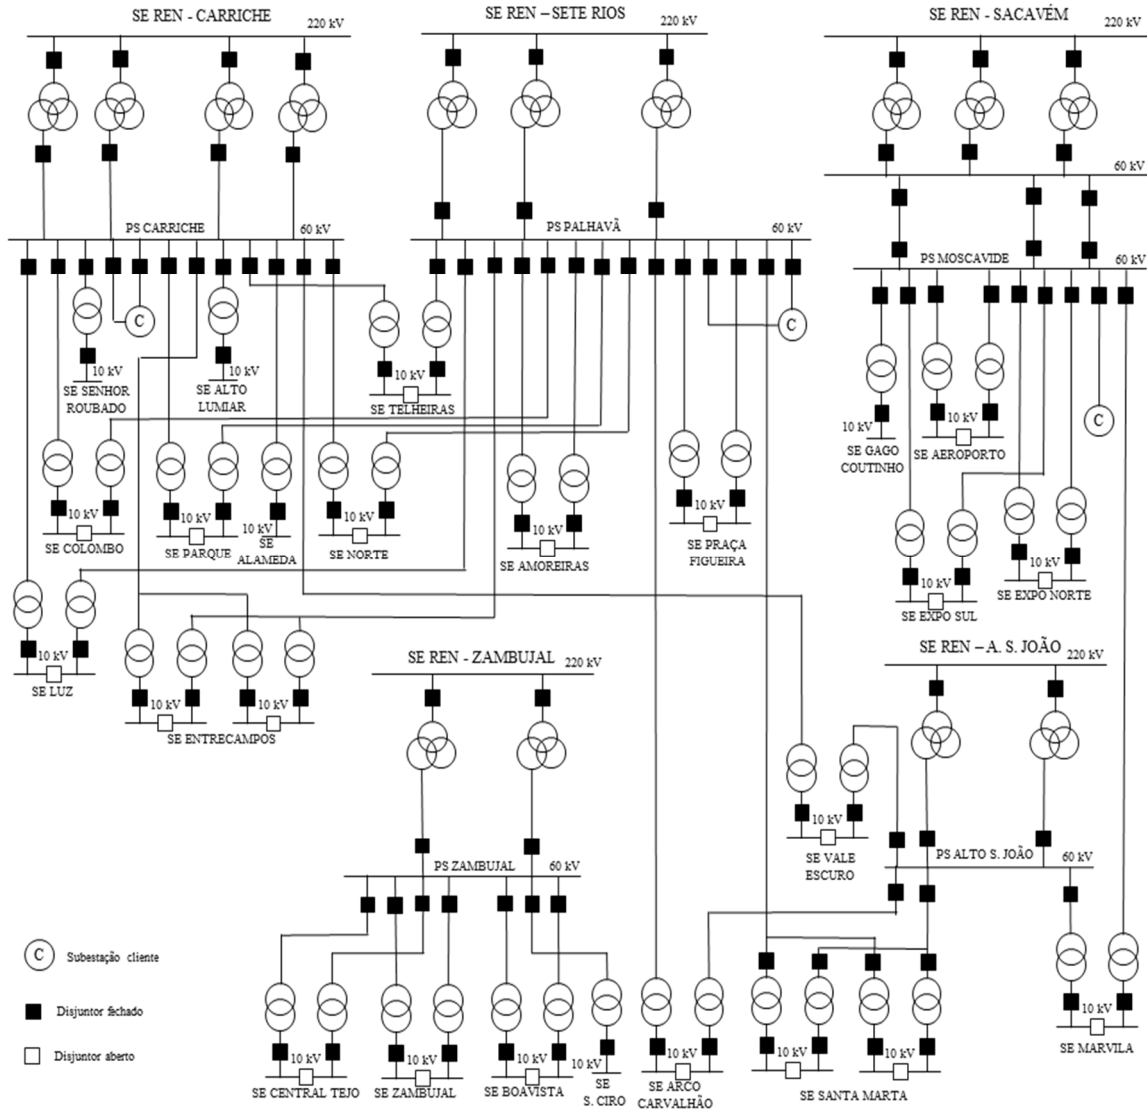


Figura 3-16: Esquema unifilar de SEs de abastecimento de energia eléctrica à cidade de Lisboa.

Esta configuração das subestações permite que estas ocupem espaços mais reduzidos, o que é importante para a rede de distribuição, devido ao custo do metro quadrado de terreno nas áreas urbanas, como Lisboa. Observa-se que cerca de metade das subestações têm são alimentadas a partir de pontos injectores diferentes, contrariando o

princípio de que a alimentação deve ter origem na fonte mais próxima, por ser mais económica (menor custo de construção e menores perdas de energia). Este esquema de alimentação cruzada entre injectores é propositado e tem por objectivo aumentar a fiabilidade do abastecimento de energia. Na falha de um ponto injector, em cada uma destas subestações ficam alimentados metade dos transformadores, que, através da interligação de barramento MT, podem alimentar os restantes circuitos MT.

Este princípio de alimentação cruzada está presente nas redes ligadas aos injectores na parte central da cidade: CARRICHE, SETE RIOS e ALTO S. JOÃO. Nos extremos nordeste e sueste, as redes dos injectores SACAVÉM e ZAMBUJAL, esta configuração ainda não tem o mesmo desenvolvimento. Existem planos para interligar estas redes, cruzando as alimentações envolvendo estes injectores (EDP Distribuição, 2018).

No conjunto das 23 subestações AT/MT na cidade de Lisboa, a potência de transformação 60/10 kV instalada é de 1320 MVA, em transformadores de 20 e 40 MVA.

Tal como foi feito com as cidades de Évora e de Porto, analisam-se alguns diagramas de carga da cidade de Lisboa de diversos períodos e épocas do ano.

É interessante novamente observar que feriados e dias especiais, como “pontes”, afectam significativamente o diagrama de carga. O efeito de um Feriado Nacional, o Dia de Portugal, de Camões e das Comunidades Portuguesas, que ocorre no dia 10 de Junho, apresenta um padrão de carga muito baixo, diferente do normal (figura 3-17). Na mesma figura vemos que a carga na 2ª Feira também está mais reduzida, devido à possibilidade de as pessoas fazerem “ponte” neste dia para terem um fim de semana prolongado. O consumo da 6ª feira também é reduzido, quase igual ao de sábado, por ser 13 de Junho, feriado municipal de Lisboa.




Figura 3-17: Diagrama de carga de semana de 9 – 15 de Junho de 2014, Lisboa.

Em comparação com o mesmo intervalo de tempo, mas de outra época do ano (mais fria) e sem influência de dias especiais, representa-se na figura 3-18 o diagrama de carga da semana 10-16 de Fevereiro. A ponta desta semana registou-se na 3ª Feira.




Figura 3-18: Diagrama de carga de semana de 10 – 16 de Fevereiro de 2014, Lisboa.

Como exemplo das séries temporais de dados colectados de um ano completo, a figura 3-19 mostra a evolução do consumo eléctrico em Lisboa em 2014.




Figura 3-19: Evolução da potência activa da cidade de Lisboa durante o ano 2014.

Na figura 3-20 estão representados os diagramas de carga para os três casos de estudo em duas semanas de Verão e de Inverno (3 – 16 de Fevereiro de 2014 e 30 de Junho – 13 de Julho de 2014). É notória a diferença da dimensão e dos perfis de consumo de energia eléctrica nestas três cidades: a carga de Lisboa é superior à do Porto mais do que duas vezes, e à de Évora – mais do que 10 vezes. A razão reside na dimensão destas cidades e nos diferentes níveis de desenvolvimento económico. Observa-se também que nos dias úteis (de segunda a sexta) o perfil da carga é semelhante, e que nos fins de semana (sábado e domingo) a carga diminui. Assim, em condições normais, estes perfis repetem-se, completando ciclos semanais. Observa-se generalizadamente uma redução de consumo no Verão, em comparação com o Inverno, embora possa haver dias quando o consumo é superior no Verão face ao Inverno. Este facto pode ser explicado pela predominância de consumos do tipo residencial e serviços, com recurso significativo aos equipamentos de ar condicionado.




Figura 3-20: Diagramas de carga de duas semanas, para os três casos de estudo.

3.3 PROCESSAMENTO INICIAL DE DADOS DE CARGA ELÉCTRICA

No início, as séries de dados foram processadas com o objectivo descobrir os dados em falta (*missing data*), remover os dados aberrantes ou corrigir as opções discrepantes (*outliers*) nos registos do sistema.

Para corrigir o problema de dados em falta, foi usada a modelagem linear de pequenos conjuntos desses dados.

Assim, para o caso de um só valor de dados em falta, este foi substituído pela respectiva média aritmética entre o valor anterior ao valor em falta e o respectivo valor posterior, calculada pela equação 3-1.

$$P(n) = P(n-1) + \frac{P(n+1) - P(n-1)}{2} = \frac{P(n-1) + P(n+1)}{2} \quad (3-1)$$

Onde $P(n)$ é o valor em falta a ser substituído pelo cálculo, $P(n - 1)$ e $P(n + 1)$ são os valores anterior e posterior ao valor faltante. A unidade de tempo considera-se igual ao quarto de hora.

No caso geral:

$$P(n) = P(n - 1) + \frac{P(m) - P(n - 1)}{m - n + 1} \quad (3-2)$$

Onde $P(m)$ é o primeiro valor de carga que foi lido após a falta de registos a partir de $P(n - 1)$.

Embora esta técnica de substituição por modelagem linear teoricamente é válida para qualquer número de registos perdidos, neste trabalho foi utilizada só para o número máximo de três registos em falta (como mostra a figura 3-21). Aqui, o primeiro valor a ser substituído, marcado por círculo, calcula-se como:

$$P(n) = P(n - 1) + \frac{P(m) - P(n - 1)}{4} \quad (3-3)$$

Se o número de dados em falta ultrapassa três, estes foram substituídos pelos dados do dia correspondente da semana anterior, se não foi feriado, ponderado ao valor médio dos valores de fronteira dos dados sãos, à mesma hora.

$$P(n) = P(n - 168) * \frac{P(k) + P(l)}{P(k - 168) + P(l - 168)} \quad (3-4)$$

Se o dia da semana anterior foi feriado, ou um dia especial, então estimaram-se os valores em falta da mesma forma, pelo dia correspondente da semana seguinte.




Figura 3-21: Modelagem linear para a substituição de valores de carga perdidos.

O mesmo procedimento foi aplicado aos dados corrompidos, como exemplo mostrado na figura 3-22.




Figura 3-22: Uma leitura de carga corrompida.

3.4 DADOS METEOROLÓGICOS

A previsão de séries temporais de carga eléctrica pode ser realizada somente com os dados da série em questão, ou além destes, podem ser utilizados dados externos (climáticos, ou meteorológicos) que eventualmente possam exercer influência nos valores futuros da série da carga.

Os factores climáticos que eventualmente possam influenciar o consumo de energia eléctrica são a temperatura ambiente, a humidade relativa do ar, a velocidade do vento, a pluviosidade e a luminosidade do dia.

Como exemplo ilustrativo, representa-se na figura 3-23 a evolução diária da temperatura média e da humidade em Portugal continental e na cidade do Porto, no período de Março de 2012 até Fevereiro de 2013 (Rodrigues, 2014). Analisando os gráficos obtém-se o que já seria de esperar, que na altura do Verão as temperaturas seriam mais altas, comparando com o Inverno, sendo precisamente o contrário, no que diz respeito à humidade, mais alta no Inverno do que no Verão.



Figura 3-23: A evolução diária da temperatura média e humidade, Portugal continental e a cidade de Porto. 03/2012 -02/2013. Obtido de (Rodrigues, 2014).

Os coeficientes de correlação temperatura/humidade correspondentes aos gráficos da figura 3-23 e a carga eléctrica dos respectivos domínios, obtidos pelo mesmo autor (Rodrigues, 2014), representam-se nas tabelas 3-1 e 3-2.

Tabela 3-1: Os coeficientes de correlação entre a carga e temperatura/humidade, Porto 2014.

	Carga
Temperatura	-0.29
Humidade	-0.04

Tabela 3-2: Os coeficientes de correlação entre a carga e temperatura/humidade, Portugal 2014.

	Carga
Temperatura	-0.28
Humidade	0.18

Os valores de correlação das tabelas 3-1 e 3-2 são baixos. Conclui-se não terem sido obtidas evidências de que a temperatura e a humidade são variáveis que têm influência nos diagramas de carga do Porto e de o todo país.

Com o objectivo de avaliar o impacto nos diagramas de carga, foram recolhidos os dados meteorológicos junto do IPMA - Instituto Português do Mar e da Atmosfera. Entre esses dados constam os de temperatura (em °C) e humidade (em %) relativa máxima, mínima e média do ar, velocidade de vento (em m/s) e radiação global (em kJ/m²). Essa informação foi recolhida nas estações automáticas localizadas nas várias zonas de país. Para o presente trabalho foram seleccionados os dados das estações automáticas meteorológicas geograficamente mais próximas dos casos de estudo (normalmente as estações automáticas ficam junto aos aeroportos ou aeródromos).

Na base desses dados foram obtidos alguns gráficos ilustrativos da evolução temporal da potência média, das temperaturas (média, mínima e máxima) e da humidade relativa (figuras 3-24 – 3-27). Todos os parâmetros mencionados têm referência diária, são relativos à cidade de Lisboa, e foram recolhidos durante o ano de 2014. Para as outras duas cidades, Porto e Évora, estes parâmetros também foram recolhidos.




Figura 3-24: A evolução diária da potência média e temperatura média. Lisboa, 2014.




Figura 3-25: A evolução diária da potência média e temperatura mínima. Lisboa, 2014.




Figura 3-26: A evolução diária da potência média e temperatura máxima. Lisboa, 2014.

Como se pode observar nas figuras acima, existe uma falta de registos dos dados meteorológicos na semana 18 – 24 de Janeiro, de que resulta uma cava em todos os gráficos de temperatura (cor azul) nesse período.

Nota-se que há maior consumo de energia eléctrica nas alturas mais frias do ano (meses de Dezembro, Janeiro, Fevereiro), devido ao uso de equipamentos de aquecimento. Nos extremos mais quentes também se observa o consumo elevado de energia, desta vez, por causa de arrefecimento das habitações, espaços comerciais, etc. Especialmente vê-se o maior consumo nas chamadas ondas de calor durante alguns períodos curtos do Verão.

No gráfico de evolução de humidade relativa (figura 3-27) também se observa uma falta de registos na mesma semana que nos gráficos de temperaturas. Desta informação meteorológica não se evidencia uma relação forte com a carga da rede eléctrica. Com grande probabilidade, a humidade relativa e a temperatura estão relacionadas e em conjunto influenciam o consumo de energia eléctrica.




Figura 3-27: A evolução diária da potência média e humidade relativa média. Lisboa, 2014.

De forma a compreender melhor qual a importância das variáveis climáticas, cujos exemplos foram apresentados nos gráficos anteriores, no diagrama de carga realizaram-se os estudos da correlação entre os dados de potência média activa e os parâmetros meteorológicos. Foram construídos os correlogramas correspondentes aos gráficos das figuras 3-24 – 3-27 e calculados os respectivos coeficientes de correlação.

Com o objectivo de anular a influência do ciclo semanal na dimensão do consumo de energia eléctrica, os correlogramas foram construídos separadamente para dias úteis, fins de semana e dias feriados. No mesmo sentido, os coeficientes de correlação foram calculados para dias úteis, Sábados, Domingos e dias feriados.

Na figura 3-28 representa-se o correlograma entre a potência média diária e a temperatura média diária, registadas na cidade de Lisboa durante o ano 2014 (a que corresponde o gráfico da figura 3-24). Nota-se, que para cada classe de dias o correlograma tem uma forma de “L”, ligeiramente levantado, resultante do aumento de potência durante os dias mais frios (3 – 10°C) e os dias mais quentes (25 – 30°C) do ano, em relação aos dias com uma temperatura mais amena.




Figura 3-28: Potência média diária vs. temperatura média diária. Lisboa, 2014.

A tabela 3-3 apresenta os coeficientes de correlação entre potência e temperatura para mesmo período de tempo.

Tabela 3-3: Coeficientes de correlação correspondentes à carga e temperatura média. Lisboa, 2014.

Todos os dias do ano	Dias úteis	Sábados	Domingos e feriados
-0.31	-0.53	-0.61	-0.56

Os resultados obtidos evidenciam uma correlação algo fraca entre a temperatura média diária e a potência média diária. Poderá considerar-se a existência de uma correlação significativa entre duas grandezas se o valor absoluto do coeficiente de correlação for superior a 0,6. Apenas para os dias de Sábado, essa relação se verifica, mas com pequena folga, o que significa que não é uma correlação muito forte. Fruto da conjugação dos diversos factores, a correlação para os diversos tipos de dias, em conjunto, é francamente fraca.

À semelhança do anterior, na figura 3-29 representa-se o correlograma entre a potência média diária e temperatura mínima diária registados na cidade de Lisboa em 2014.




Figura 3-29: Potência média diária vs. temperatura mínima diária. Lisboa, 2014.

Analogamente, a interdependência entre a potência média diária e temperatura máxima diária para o mesmo local e o mesmo período de tempo, está representada na figura 3-30.




Figura 3-30: Potência média diária vs. temperatura máxima diária. Lisboa, 2014.

Nas tabelas 3-4 e 3-5 apresentam-se os coeficientes de correlação calculados para os correlogramas das figuras 3-29 e 3-30, entre a potência média diária e as temperaturas máximas e mínimas.

Tabela 3-4: Coeficientes de correlação correspondentes à carga e temperatura mínima diária. Lisboa, 2014.

Todos os dias do ano	Dias úteis	Sábados	Domingos e feriados
-0.28	-0.56	-0.47	-0.60

Tabela 3-5: Coeficientes de correlação correspondentes à carga e temperatura máxima diária. Lisboa, 2014.

Todos os dias do ano	Dias úteis	Sábados	Domingos e feriados
-0.33	-0.56	-0.55	-0.63

Os valores numéricos de coeficientes de correlação para os três tipos de estudo representados em cima são relativamente baixos, não evidenciando a existência de correlação forte entre as grandezas em análise.

Como as variáveis climáticas incluem não somente a temperatura, mas também a humidade, nebulosidade, o rumo e intensidade do vento, foram também analisadas as interdependências entre a carga e essas variáveis. Como título de exemplo deste tipo de análise, na figura 3-31 representa-se o correlograma entre a potência média diária e humidade relativa média diária registada na cidade de Lisboa em 2014. A tabela 3-6 apresenta os coeficientes de correlação entre potência e humidade para o mesmo período de tempo.




Figura 3-31: Potência média diária vs. humidade relativa média diária. Lisboa, 2014.

Tabela 3-6: Coeficientes de correlação correspondentes à carga e humidade relativa média diária. Lisboa, 2014.

Todos os dias do ano	Dias úteis	Sábados	Domingos e feriados
0.16	0.16	0.24	0.38

Os resultados apresentados na Tabela 3-6 indicam que praticamente não existe correlação entre o consumo de energia e a humidade relativa do ar.

Conforme os resultados obtidos, concluiu-se que só a temperatura do ar apresenta uma correlação significativa com a potência activa, e mesmo assim com valores baixos. É praticamente inexistente a correlação entre a potência e as restantes variáveis climáticas: humidade do ar, velocidade do vento e nebulosidade. Assim, definiu-se que o vector de entrada do modelo de previsão proposto, cuja composição está descrita no capítulo seguinte, vai incluir só as variáveis da potência, desprezando os dados meteorológicos. A inclusão dos parâmetros climáticos no modelo requer desenvolvimentos adicionais do estudo do seu impacto no diagrama de cargas.

Estudos de outros autores portugueses também demonstraram que os factores meteorológicos (entre os quais a temperatura é o mais significativo) não afectaram muito a previsão de carga a curto prazo (Santos, Martins, & Pires, Designing the input vector to ANN-based models for short-term load forecast in electricity distribution systems, 2007), (Fidalgo & Lopes, 2005). A região em estudo, Portugal, é um país com clima mediterrâneo, onde as mudanças bruscas de temperatura são raras. O modelo de previsão é capaz de se moldar e adaptar às pequenas mudanças de temperatura num curto espaço de tempo. No trabalho (Fidalgo & Lopes, 2005) foi demonstrado que havia um ganho insignificante quando o factor de temperatura era utilizado como entrada da rede. Além disso, no estudo (Fidalgo & Matos, 2007), onde no vector de entrada foi incluída a variável de temperatura, foi demonstrado que mesmo para o menor erro de previsão de temperatura considerado, o desempenho de redes neuronais foi pior que em casos sem inclusão de temperatura. Isso confirma a conclusão de que, nestes casos, a temperatura pode não ser incluída no processo de previsão de carga.

3.5 CONCLUSÕES

Descritos e analisados os diagramas de carga dos três casos de estudo concluiu-se que estes têm padrões diferentes, em função do maior ou menor peso dos sectores de actividade industrial, serviços, ou doméstico, presentes em cada caso. A cidade de Évora tem um padrão predominantemente residencial, enquanto o consumo na cidade do Porto, para além do consumo residencial, tem uma significativa componente industrial e de serviços, que é evidenciada pelos picos de carga de manhã, nos dias úteis. A cidade de Lisboa tem predominância dos padrões de consumo residencial e serviços, que é evidenciada pela existência de dois picos diários (fim da manhã e início da noite) e pelo crescimento da carga nos meses de Verão (excepto Agosto), face aos meses da Primavera e do Outono.

Devido à existência de erros e dados em falta, procedeu-se à sua substituição por valores estimados, utilizando-se diversos métodos de estimação, descritos no corpo do capítulo.

Analisada a influência das variáveis climáticas na carga eléctrica da rede e não tendo sido obtida uma correlação significativa entre as grandezas, optou-se por não incluir as variáveis climáticas no vector de entrada. Num trabalho de investigação futura, os parâmetros climáticos poderão ser introduzidos no modelo com maior horizonte de previsão e na eventual inclusão de um modelo que apenas contemple as pontas.

Modelo de previsão proposto

Neste capítulo descreve-se a metodologia de redes neuronais que em combinação com os padrões de carga em patamares e injeção do sinal aleatório foi adoptada para o modelo previsor neste trabalho. Apresenta-se detalhadamente a composição do vector de entrada do modelo.

4.1 INTRODUÇÃO

Séries temporais são um conjunto de observações de um fenómeno ordenadas numa sequência de tempo. A previsão de séries temporais consiste em prever valores da série em horizontes futuros. Quando a série pode ser descrita por uma função matemática a série é classificada como determinística e quando envolve também componentes aleatórios a série é dita estocástica.

Os modelos baseados em Redes Neurais Artificiais (RNA) são utilizados com sucesso na previsão de séries temporais, onde há uma forte componente de não linearidade. Este facto pode ser explicado pela capacidade que uma rede neural tem de funcionar como um aproximador universal, ou seja, a rede pode capturar qualquer tipo de comportamento, não importando o quão complexo ele seja. A grande dificuldade é a determinação da topologia óptima da rede.

Neste trabalho foi implementada uma metodologia híbrida de previsão do diagrama de carga para a hora seguinte e para o dia seguinte, utilizando as vantagens das técnicas baseadas nas RNA combinadas com uma inovadora abordagem de composição do vector de entrada dessas redes. São as duas principais razões para o uso de redes neurais como ferramenta de previsão de carga: elas podem aproximar numericamente qualquer função desejada e não são dependentes de modelos físicos de sistemas.

A Fig. 4-1 descreve a estrutura geral do trabalho desenvolvido na forma de um diagrama de blocos.

Das bases de dados dos sistemas de telecontagem de energia ou dos sistemas de aquisição de dados (SCADA) dos operadores da rede, foram obtidas as séries temporais dos valores de carga, os diagramas de carga, das redes em análise do período passado (1º bloco). Estas séries são tratadas preliminarmente com vista a serem completadas com os dados em falta e a serem corrigidos os dados errados (2º bloco).

Segue-se a preparação da RNA, compondo um vector de entrada com os dados obtidos do bloco anterior, através do seu processamento mais ou menos complexo, conforme a constituição desse vector. Seguem-se as fases de treino e de validação da RNA (3º bloco).

A previsão da carga eléctrica é a operação que fornece a série de valores de carga prevista com o prazo definido (4º bloco). Essa série de valores será então utilizada nos processos de planeamento do sistema produtor e de operação da rede (5º bloco).

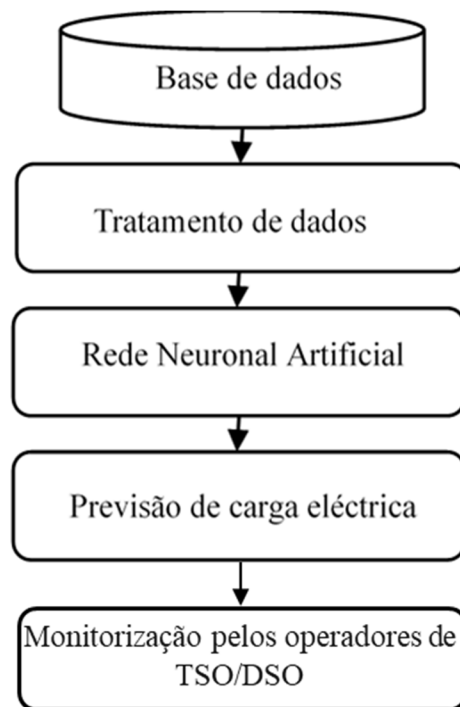


Figura 4-1: Diagrama de blocos do modelo de previsão

Na composição do vector de entrada de RNA é utilizada a carga em instantes anteriores, bem como, o diagrama de patamares de carga baseado no diagrama de carga médio, e um sinal aleatório com vista a estimular a rede de modo a prever as alterações mais aleatórias de cada instante (figura 4-2).

O uso do sinal aleatório como uma das variáveis no vector de entrada, bem como os patamares de carga, é inovador na área dos estudos sobre a previsão de energia eléctrica a curto prazo em média tensão.

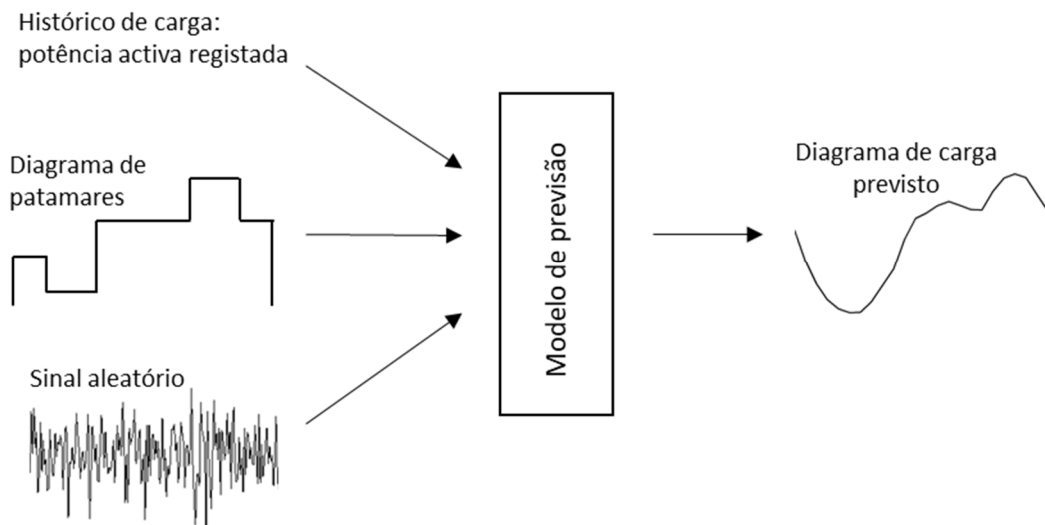


Figura 4-2: Esquema conceptual do modelo de previsão desenvolvido.

4.2 REDES NEURONAIIS ARTIFICIAIS: BREVE REFERENCIAL TEÓRICO

Uma Rede Neuronal Artificial é composta por várias unidades de processamento (neurónios artificiais), cujo funcionamento é bastante simples. O modelo do neurónio é inspirado no sistema nervoso biológico: o neurónio recebe os valores de entrada (x_i) que são ponderados por valores associados com cada sinapse (w_i), chamados pesos sinápticos. Todos os valores ponderados são somados inicialmente, que resulta no nível de actividade do neurónio (v) que a seguir é processado pela função de activação ($\phi(\cdot)$) para o valor de saída (y). A figura 4-3 apresenta esquematicamente o modelo do neurónio artificial.




Figura 4-3: Esquema de um neurónio artificial.

A grande vantagem no uso de RNA para solução de problemas complexos provém, principalmente, de sua capacidade de aprendizagem através de exemplos e generalização da resposta adquirida durante o treino da rede. O treino é um conjunto de regras adicionadas às RNAs de modo a aumentar a sua capacidade de generalização. Ao ajustar os pesos das conexões entre os neurônios é possível atingir a generalização.

Um dos largamente difundidos dos algoritmos de treino é o *Backpropagation* (Hippert, Pedreira, & Sousa, 2001). É o algoritmo que busca minimizar o erro da aprendizagem, pelo método do gradiente descendente, através da correcção dos pesos no sentido contrário à propagação da informação. Esse tipo de treino requer várias iterações de ajustes de pesos para que os resultados obtidos se aproximem dos resultados desejados. Determinar o número exato de iterações é outro desafio no treino das redes MLP uma vez que um número alto de iterações pode causar um ajustamento por excesso ou *overfitting* fazendo com que a rede decore os resultados e perca a capacidade de generalização. Por outro lado o baixo número de iterações pode causar problemas na convergência da rede.

Como critério de parada do treino da rede usa-se técnica da validação cruzada. Ao invés de definir o número exato de iterações de ajuste de pesos no treino divide-se aleatoriamente o conjunto de dados em 3 subconjuntos: treino, validação e testes. Com isso, a cada iteração do *backpropagation*, a rede treinada, já com os pesos ajustados, é testada com o subconjunto de validação e o erro da predição é calculado ao final da iteração.

Resumindo, o algoritmo de *backpropagation* pode ser descrito através dos procedimentos seguintes (Farias, 2008):

1. Apresentação de uma série temporal de dados $x_1, x_2 \dots x_m$ (padrão) da rede, a qual fornece uma saída y .
2. Cálculo do erro que é igual à diferença entre o valor desejado (alvo) e a saída para cada valor de y .
3. Cálculo do erro retropropagado pela rede associado à derivada parcial do erro quadrático de cada elemento relacionado aos pesos $\omega_1, \omega_2 \dots \omega_i$.
4. Ajuste dos pesos de cada elemento.

5. Apresentação de um novo padrão da rede e repetição do processo até que haja a convergência da rede: valor absoluto do erro < tolerância arbitrada.

4.3 CONSTRUÇÃO DO VECTOR DE ENTRADA

4.3.1 INTRODUÇÃO

Depois de as séries temporais serem previamente processadas, com vista à substituição de dados em falta e correcção de erros (como foi descrito no capítulo 3) , surge problema da determinação de conjunto de entradas a serem utilizados pelo modelo de previsão baseado em RNA.

No estudo (Lourenço & Santos, 2012) mostra-se que *Gaussian estimator processes* pode ser usado para a modelagem de sistemas dinâmicos descritos em geral pela equação seguinte:

$$y(k) = f(x(k)) + \epsilon(k) \quad (4-1)$$

onde $y(k)$ e $x(k)$ são variáveis de saída e de entrada, respectivamente, $\epsilon(k)$ é o ruído branco gaussiano não correlacionável com a variância v_0 , $\epsilon \sim \mathcal{N}(0, v_0)$.

Em geral, o vector de entrada depende das variáveis endógenas z e exógenas u , tomadas com um atraso temporal L (Rasmussen & Williams, 2006):

$$X(k) = [z(k-1), z(k-2), \dots, z(k-L), u(k-1), \dots, u(k-L)] \quad (4-2)$$

As variáveis endógenas são os valores de potência activa no passado, ou seja, anterior ao momento de previsão $t = k$. Entre as variáveis exógenas mencionam-se a temperatura do ar, a humidade, a velocidade do vento, etc.

Num exemplo simples da figura 4-4 estão marcados a variável a prever $P(t)$ (para o caso de previsão para a hora seguinte) e as duas mais próximas com os respectivos

atrasos uma e duas horas. Estas últimas são dois valores contíguos de potência activa, $P(t-1)$ e $P(t-2)$. O diagrama se refere ao dia 1 de Janeiro de 2014 da cidade de Évora.




Figura 4-4: A variável de previsão $P(t)$ e as duas anteriores, $P(t-1)$ e $P(t-2)$.

É importante escolher correctamente as variáveis que vão compor o vector de entrada com os respectivos atrasos, ou seja, escolher os valores do passado que mais influenciam os valores futuros. Muitas vezes, selecciona-se por método de tentativa e erro, entre vários conjuntos alternativos de variáveis-candidatas ao vector $X(k)$. O modelo-regressor fica avaliado pelo seu bom alcance do resultado de previsão. A título de exemplo, menciona-se o método chamado *based regressor selection*, ou *exhaustive search for best regressors* (Lind & Ljung, 2005).

4.3.2 AUTOCORRELAÇÃO DAS SÉRIES TEMPORAIS DE POTÊNCIA ACTIVA

Com o objectivo de um melhor entendimento das séries temporais de carga envolvidas, foi realizado um estudo estatístico para detectar a auto correlação existente nas séries temporais. Observou-se que a correlação dos dados depende da distância temporal entre os mesmos onde são evidentes os picos mais destacados com determinados atrasos. Como exemplo, a figura 4-5 apresenta a evolução dos coeficientes de autocorrelação para a série de dados de potência activa da cidade de Lisboa no período de duas semanas (1-15 de Janeiro de 2014).




Figura 4-5. Evolução dos coeficientes de autocorrelação de potência activa.

Os coeficientes de autocorrelação com as maiores amplitudes obtidos da correlograma anterior, foram reunidos na tabela 4-1.

Tabela 4-1: Principais coeficientes de autocorrelação identificados nas séries de carga de Lisboa, 2014.

	P(t)	P(t-1)	P(t-2)	P(t-3)	P(t-23)	P(t-24)	P(t-25)	P(t-167)	P(t-168)	P(t-169)
P(t)	1.000	0,963	0,861	0,710	0,818	0,850	0,814	0,924	0,961	0,925

Para as cidades de Porto e Évora foram obtidos os gráficos e as tabelas com coeficientes de autocorrelação idênticos.

Como seria de esperar, os coeficientes de autocorrelação mais altos são os com atraso de uma hora e uma semana: entre P(t) e P(t-1), P(t) e P(t-168). Torna-se evidente de observação simples dos coeficientes da tabela 4-1, que no vector de entrada podem ser incluídos os valores homólogos relativos ao dia anterior da previsão e à semana anterior, bem como os valores adjacentes. Estes valores adjacentes, tomados em conjunto, indicam a tendência de evolução da carga eléctrica que está relacionada com o conceito de derivada/gradiente - *derivative term concept* (Lourenço & Santos, 2012). Por exemplo, considerando o atraso de uma semana, as variáveis que caracterizam a tendência de consumo, são P(t-167), P(t-168) e P(t-169). As variáveis com natureza de gradiente são tomadas como diferença entre valores adjacentes: $\Delta_i = P(t-167) - P(t-168)$ e $\Delta_{i+1} = P(t-168) - P(t-169)$. O gradiente mostra pelo seu sinal (positivo ou negativo), se a função cresce ou decresce. Ou seja, é possível observar a tendência de comportamento da função no passado nos curtos intervalos de tempo. Como será apresentado no

capítulo 5, a incorporação dos conceitos de tendência e de gradiente melhora o desempenho das redes neurais utilizadas no trabalho.

Relativamente as pontas de carga diários, notou-se também uma sazonalidade semanal nos dados. Mas a ponta de carga não apresentou uma correlação significativa com nenhum atraso em especial, ocorrendo apenas um pequeno pico para atrasos múltiplos de uma semana.

4.3.3 A INCLUSÃO NO VECTOR DE ENTRADA DAS VARIÁVEIS DE PATAMARES DE CARGA E DO SINAL ALEATÓRIO

Uma das ideias inovadoras deste trabalho consiste na inclusão no vector de entrada as variáveis (juntamente com as descritas anteriormente) relativas aos diagramas de patamares, baseados nos diagramas médios diários, com a posterior injeção de sinais aleatórios (figura 4-6).




Figura 4-6: Sequência simbolizada de implementação do sinal aleatório injectado no diagrama de patamares.

O objectivo do diagrama de patamares é introduzir um parâmetro no vector de entrada que possa caracterizar o tipo de dia, útil, Sábado, Domingo ou feriado, que o método de previsão possa reconhecer na hora a prever e que por essa forma se obtenham melhores resultados.

Sendo o gráfico geometricamente rectilíneo, o diagrama de patamares (perfil normalizado da carga) também ajuda identificar os períodos do dia mais propícios à ocorrência de picos de carga, pois é nesses períodos que é necessária uma previsão de boa qualidade. Além do elevado nível da procura de energia, a sua grande variação é um factor crítico que requer do sistema uma enorme capacidade de tomada de carga e maior utilização dos recursos de geração. Uma previsão de má qualidade pode levar o sistema a operar com risco elevado, ou, em casos extremos, até a cortes de carga (Hong, 2015).

4.3.4 OBTENÇÃO DE PADRÕES DE DIAGRAMA DE CARGA NA FORMA DE PATAMARES

Para melhorar o desempenho do modelo de previsão desenvolvido, acrescentaram-se os valores de patamares de carga no vector de entrada do modelo, como mais uma variável endógena. Os patamares são agregações de carga em intervalos de várias horas consecutivas. Em geral, servem para simplificar a quantidade de informação utilizada na análise e procedimentos de fenómenos que ocorrem na operação dos sistemas eléctricos (Farias, 2008).

A carga pode ser agregada em intervalos temporais dentro de um mesmo dia. A ideia a utilizar no método desenvolvido já é largamente utilizada no sistema tarifário. Em Portugal, de acordo com ERSE, existem quatro níveis de carga, cada um com o seu horário de ocorrência:

1. Ponta
2. Cheias
3. Vazio normal
4. Super vazio

Segundo o Regulamento Tarifário da Entidade Reguladora dos Serviços Energéticos (ERSE) em Portugal, os períodos horários de entrega de energia eléctrica a clientes finais são diferenciados em ciclo semanal e ciclo diário. Esses períodos horários são determinados, tendo em consideração as especificidades eléctricas de cada região designadamente no que respeita à evolução do seu diagrama de carga (Apolinário, et al., 2006). O Regulamento prevê a repartição dos períodos horários em Ponta, Cheias, Vazio normal e Super vazio para os dias úteis, sábado e domingo. No fim de semana

(sábado e domingo), o número de períodos horários é mais reduzido, chegando no domingo só a dois períodos: Vazio normal e Super vazio (ERSE, 2017).

A tabela 4-2 apresenta os intervalos dos respectivos níveis de carga, nos períodos de horário de Inverno e de Verão em Portugal.

Tabela 4-2: Os intervalos de patamares de ciclo semanal, retirado de (ERSE, 2017).

Ciclo semanal opcional para MAT, AT e MT em Portugal Continental			
Período de hora legal de Inverno		Período de hora legal de Verão	
De segunda-feira a sexta-feira		De segunda-feira a sexta-feira	
Ponta:	17.00/22.00 h	Ponta:	14.00/17.00 h
Cheias:	00.00/00.30 h 07.30/17.00 h 22.00/24.00 h	Cheias:	00.00/00.30 h 07.30/14.00 h 17.00/24.00 h
Vazio normal:	00.30/02.00 h 06.00/07.30 h	Vazio normal:	00.30/02.00 h 06.00/07.30 h
Super vazio:	02.00/06.00 h	Super vazio:	02.00/06.00 h
Sábado		Sábado	
Cheias:	10.30/12.30 h 17.30/22.30 h	Cheias:	10.00/13.30 h 19.30/23.00 h
Vazio normal:	00.00/03.00 h 07.00/10.30 h 12.30/17.30 h 22.30/24.00 h	Vazio normal:	00.00/03.30 h 07.30/10.00 h 13.30/19.30 h 23.00/24.00 h
Super vazio:	03.00/07.00 h	Super vazio:	03.30/07.30 h
Domingo		Domingo	
Vazio normal:	00.00/04.00 h 08.00/24.00 h	Vazio normal:	00.00/04.00 h 08.00/24.00 h
Super vazio:	04.00/08.00 h	Super vazio:	04.00/08.00 h

Em outros países a agregação de carga é diferente. No sector eléctrico brasileiro, por exemplo, os patamares de carga, ligadas ao sistema tarifário, definem-se como os de carga leve, média e pesada. A figura 4-7 dá exemplo desses patamares de carga juntamente com o diagrama de carga diário (Farias, 2008).




Figura 4-7: Um diagrama de carga diário com os respectivos patamares de carga, obtido de (Farias, 2008).

O diagrama de patamares cronológico do exemplo anterior podia ser obtido colocando no eixo vertical os valores de cada patamar segundo a ordem cronológica e respeitando a duração real de patamares. A tabela 4-3 ilustra a distribuição de patamares de carga conforme o exemplo descrito em cima.

Tabela 4-3: Os intervalos cronológicos de patamares de ciclo diário (segundo o exemplo da figura 4-7).

Horas	Carga
0 - 7	Leve
8 - 18	Média
19 - 21	Pesada
22 - 24	Média

No presente trabalho os patamares de carga foram construídos na base de padrões de carga diários. Padrão de carga definiu-se como o diagrama de carga média agregada conforme as estações do ano e o tipo de dia (útil, Sábado, Domingo ou feriado).

Os valores dos patamares identificam-se conforme os níveis agregados de carga. Os intervalos temporais dos patamares são diferentes dos usados no sistema tarifário, aproximando-se ao comportamento real do diagrama de carga. Em cada diagrama, a duração dos patamares é obtida, minimizando a soma das diferenças (em módulo) entre o diagrama de carga médio do tipo de dia analisado e o diagrama de patamares.

Para cada tipo de dia identificado, por exemplo, dia útil de Inverno, calcula-se o diagrama de carga diário médio do ano anterior ao da previsão. Em seguida, agregam-se os intervalos de tempo (horas), tomando a carga média do intervalo constante nesse agregado. O número de agregados (patamares) e o número de horas agregadas em cada patamar (duração) foram obtidos num compromisso de minimização da função F e do número de patamares.

Para um número de patamares definido inicialmente (dois), procedeu-se à minimização da função F (equação 4-3). Foi-se aumentando o número de patamares até o valor de F já não reduzir significativamente, atingindo valores na ordem dos 5%.

$$F = \frac{1}{24} \sum_{k=1}^m \left(\sum_{i \in T_k} |P_{\text{diag},i} - P_{\text{pat},k}| / P_{\text{pat},k} \right) \quad (4-3)$$

onde:

m – número de patamares;

T_k – conjunto de períodos incluídos no patamar k ;

i – período (hora);

$P_{\text{diag},i}$ – carga do diagrama médio de carga do tipo de dia e estação do ano;

$P_{\text{pat},k}$ – carga do patamar k :

$$P_{\text{pat},k} = \frac{\sum_{i \in T_k} P_{\text{diag},i}}{|T_k|} \quad (4-4)$$

Desta forma obteve-se que, geralmente, o número de patamares suficiente para uma boa aproximação é de três, nos dias úteis, e de dois, nos restantes tipos de dias da semana.

Tendo a base de dados de carga previamente consolidada, podem-se estabelecer vários padrões de diagramas (diagramas de patamares), um para dias úteis, um para sábados e outro para os domingos dias feriados (*holidays*), para cada estação do ano (Verão, Outono, Inverno, Primavera). O impacto de dias especiais, como pontes, também pode ser considerado.

Sendo assim, os diagramas diários médios de carga podem ser obtidos para cada estação do ano e para cada um dos conjuntos de dias úteis, Sábados, Domingos, feriados, pontes, estabelecendo-se vários padrões.

A título de exemplo de apresentação gráfica de cálculo de patamares, na figura 4-8 está representado o diagrama médio de Inverno em Lisboa no ano 2014. A cada hora do dia corresponde o seu nível de patamar. Neste exemplo há só três níveis de patamares correspondentes às letras A, B e C. Os erros calculados (valores da função F) para cada tipo de dia estão na coluna do lado direito e estão dentro da tolerância considerada de cerca de 5%.




Figura 4-8: Diagrama diário médio de Inverno com os níveis de patamares correspondentes, Lisboa 2014.

As designações de tipos de dia são as seguintes: DU – dia útil; SA – Sábado; DF – Domingo/feriado; I – Inverno; P – Primavera; V – Verão; O – Outono.

Os diagramas diários médios e os respectivos diagramas de patamares foram construídos para todas estações do ano, mas na figura 4-8 só estão apresentadas os de Inverno (senão, a leitura dos gráficos seria difícil por causa de muitas curvas desenhadas no mesmo plano).

O mesmo estudo foi feito também para as cidades do Porto e de Évora.

Figura 4-9 ilustra os diagramas diários médios e os diagramas de patamares construídos na base de três níveis (correspondentes às letras A, B e C da figura 4-8) para a cidade de Porto para a época de Inverno, e a figura 4-10 – para a época de Verão.




Figura 4-9: Diagrama diário médio de Inverno com os 3 níveis de patamares correspondentes, Porto 2014.




Figura 4-10: Diagrama diário médio de Verão com os 3 níveis de patamares correspondentes, Porto 2014.

Como mais um exemplo de patamares correspondentes aos vários tipos de dia e estações de ano, as figuras 4-11 e 4-12 ilustram o perfil dos patamares do diagrama de carga da cidade de Évora do ano 2014. Foi verificado que no caso da época de Inverno era suficiente três níveis de patamares para uma boa aproximação, e para a época de Verão - só dois níveis.




Figura 4-11: O diagrama diário médio de carga de Inverno com os respectivos 3 níveis de patamares. Évora, 2014.




Figura 4-12: O diagrama diário médio de carga de Verão com os respectivos 2 níveis de patamares. Évora, 2014.

Acrescenta-se que até ao presente, entre as publicações científicas, não se encontrou nenhum trabalho onde a utilização dos patamares de carga serviu para a previsão do consumo de energia para o dia seguinte. Embora no trabalho (Farias, 2008) propõe-se

um método de previsão de patamares de carga, mas usa-se a forte ligação ao sistema tarifário brasileiro.

4.3.5 INJEÇÃO DO SINAL ALEATÓRIO

A ideia de incluir no vector de entrada o sinal aleatório surgiu do simples facto de que o sinal original, que representa a carga eléctrica, varia instantaneamente. E como os patamares de carga têm valor constante durante algum intervalo de tempo, o sinal aleatório pode tornar o comportamento do patamar mais dinâmico. Por outro lado, a decomposição da série temporal de carga mostra que esta, em geral, possui nem só componentes cíclica, sazonal e tendencial, mas também aleatória. Assim, torna-se possível usar a componente aleatória da série temporal como uma das variáveis do vector de entrada de RNA.

O sinal aleatório foi sobreposto aos patamares e pretende introduzir um estímulo ao modelo durante os períodos que duram estes patamares. Por sua vez, a tendência, como está descrito no subcapítulo 5.2, reflecte a introdução do conceito de derivada no vector de entrada e dá informação sobre o comportamento futuro da carga com base na informação passada.

Neste trabalho o sinal aleatório foi obtido através de funções que utilizam o algoritmo *Mersenne Twister* (MT19937) para gerar uma série de números aleatórios dentro de uma banda pré-definida (Matsumoto & Nishimura, 1998). A seguir, o valor numérico do sinal foi adicionado ao valor de patamar de carga em cada momento de tempo.

A figura 4-13 ilustra a injeção do sinal aleatório nos patamares do diagrama de carga correspondente ao dia útil representado da figura 4-11, com o sinal aleatório de resolução de um quarto de hora que oscila em torno dos patamares. Podemos variar a amplitude (valor máximo) do sinal aleatório. Neste exemplo a amplitude é de 1MW.




Figura 4-13: Exemplo de sinal aleatório injectado no diagrama de patamares (cidade de Évora, dia útil de Inverno).

4.4 CONCLUSÕES

Com o objectivo de tornar mais impactante a especificidade do tipo do dia da semana no método de previsão do diagrama de cargas, dado se ter constatado ser esse um dos factores mais determinantes no valor do consumo, é proposta uma abordagem inovadora de inclusão de parâmetros denominados patamares no vector de entrada da RNA.

Cada patamar corresponde ao nível de carga no diagrama médio de carga agregada por estação do ano e por tipo de dia (útil, Sábado, Domingo e feriado). A duração de cada patamar de carga foi obtida, minimizando o somatório dos resíduos (em módulo) entre o diagrama de carga médio diário e o nível de carga do patamar. Obteve-se que o número de patamares suficiente para uma boa aproximação é de três, ou de dois, conforme o caso de estudo e conforme se trata de dias úteis ou fins-de-semana (e feriados), ou ainda conforme as estações do ano. Para avaliação comparativa dos resultados, foram criadas várias alternativas de diagramas de patamares, considerando duas ou quatro estações do ano, dois ou três patamares.

Com o objectivo de melhorar o rigor da previsão são avaliadas alternativas de vector de entrada com injeção de um sinal aleatório que é adicionado ao valor do patamar em cada momento temporal de previsão.

O uso do sinal aleatório como uma das variáveis no vector de entrada, bem como os patamares de carga considerados no nosso trabalho, é algo inovador na área dos estudos sobre a previsão de energia eléctrica a curto prazo em média tensão.

Implementação do modelo e os resultados obtidos

Neste capítulo descrevem-se o ambiente computacional e os parâmetros estatísticos usados para a análise do erro do modelo de previsão da carga. Apresenta-se o procedimento de ajuste de dimensão de vector de entrada de RNA para dois tipos de previsão: hora seguinte e dia seguinte. Os resultados de previsão acompanham o texto na forma numérica e gráfica.

5.1 O MEIO COMPUTACIONAL USADO PARA A PREVISÃO DA CARGA

Para validar o modelo de previsão da carga proposto neste trabalho, foram realizados vários testes e ensaios.

Conforme foi descrito no capítulo 4 implementou-se um método baseado no algoritmo da retropropagação do erro (*backpropagation*), Levenberg-Marquardt. Este algoritmo é considerado um dos mais rápidos para treino de redes feedforward *backpropagation*, que possui uma quantidade moderada de pesos sinápticos. Essencialmente baseia-se na determinação das derivadas de segunda ordem do erro quadrático em relação aos pesos, diferindo do algoritmo *backpropagation* tradicional que considera as derivadas de primeira ordem. Assim, para uma quantidade moderada de dados, este método possui uma óptima actuação com redução do número de iterações. Porém, tem um tempo maior de processamento, o que para este tipo de metodologia não é significativo, dado que o treino não é executado em tempo real. Este tipo de metodologia permite ainda o ajuste e a definição da topologia da rede neuronal bem como o ajuste dos parâmetros de treino, o número de iterações no treino, e a taxa de aprendizagem (Hippert, Pedreira, & Sousa, 2001).

O conjunto de treino e validação é usado para ajustar os parâmetros do modelo proposto, enquanto que o conjunto de teste é utilizado para medir o desempenho do modelo.

As séries temporais de potência foram divididas em três conjuntos de dados: conjunto de treino (com 50% dos dados), conjunto de validação (com 25% dos dados) e conjunto de teste (com 25% dos dados).

No caso da previsão da carga para hora seguinte, os dados do ano 2013 foram utilizados para os treinos de previsão e os do ano 2014 – para a simulação. Para a previsão da carga para 24 horas seguintes, o ano 2014 foi o dos treinos, e o ano 2015 – o da simulação. Assim, os dados de simulação e produção de resultados finais nunca foram incluídos no processo de treino da RNA.

O número óptimo de neurónios na camada oculta foi determinado durante os treinos da rede neuronal, por tentativas, começando com metade da camada de entrada. A função tangente hiperbólica foi escolhida para a camada oculta. Utilizou-se uma função

linear para a camada de saída. O vector de entrada foi normalizado entre -1 e 1. Este é um arranjo bem comprovado e adequado, quando, como no caso presente, as relações entre as variáveis em jogo têm um forte comportamento não-linear. Em vários modelos de previsão de curto prazo este tipo de estrutura de RNA é amplamente utilizado (Hippert, Pedreira, & Sousa, 2001), (Santos, Martins, & Pires, Designing the input vector to ANN-based models for short-term load forecast in electricity distribution systems, 2007), (Chemetova, Santos, & Ventim-Neves, 2017).

O desempenho da previsão foi avaliado com base nos indicadores estatísticos apresentados na Tabela 5-1:

Tabela 5-1: Parâmetros estatísticos para a análise do erro do modelo de previsão.

Erro absoluto <i>Absolute error</i>	$e_t = P_t - \hat{P}_t$
Percentagem do erro <i>Percentage error</i>	$PE_t = \frac{(P_t - \hat{P}_t)}{P_t} 100\%$
Percentagem média do erro <i>Mean percentage error</i>	$MPE = \frac{1}{n} \sum_{t=1}^n PE_t$
Percentagem média absoluta do erro <i>Mean Absolute Percentage Error</i>	$MAPE = \frac{1}{n} \sum_{t=1}^n PE_t $
Raiz quadrada da percentagem média quadrática <i>Root Mean Square Percentage Error</i>	$RMSPE = \sqrt{\frac{1}{n} \sum_{t=1}^n PE_t^2}$

Nestas expressões, P_t é o valor de potência registado pelo sistema de telecontagem (real), \hat{P}_t é o valor de potência calculado (previsto), n é o número de registos (membros de amostra).

Mean absolute percentage error (MAPE) é o indicador estatístico mais divulgado na bibliografia sobre os métodos de previsão de carga eléctrica. Quanto menor o valor do MAPE, melhor o desempenho da previsão (Hippert, Pedreira, & Sousa, 2001).

Neste trabalho a previsão da carga foi realizada para dois horizontes de curto prazo: para a hora seguinte e para o dia seguinte.

Para as previsões da hora seguinte o vector de saída das redes neuronais é composto só por um único elemento, e para as 24 horas seguintes – por 24 elementos.

A dimensão e a escolha das variáveis que vão compor o vector de entrada final têm que ser realizadas com muito rigor e cuidado, porque delas depende o êxito do modelo sugerido.

A seguir descreve-se o procedimento de ajuste de dimensão via experimental de vector de entrada de RNA para dois tipos de previsão: hora seguinte e dia seguinte. Apresentam-se também os resultados na forma numérica e gráfica.

5.2 PREVISÃO PARA A HORA SEGUINTE

Para se atingir a previsão do DC do dia seguinte, numa primeira fase, foi explorado o horizonte da hora seguinte. O esquema simplificado deste sistema de previsão está ilustrado na figura 5-1.




Figura 5-1: Esquema simplificado da previsão de potência para a hora seguinte.

Para este tipo de previsão foram testadas duas versões de composição do vector de entrada: com e sem as variáveis de patamares e sinal aleatório.

A composição do vector de entrada correspondente à opção simples (sem as variáveis de patamares e sinal aleatório) está representada na figura 5-2.

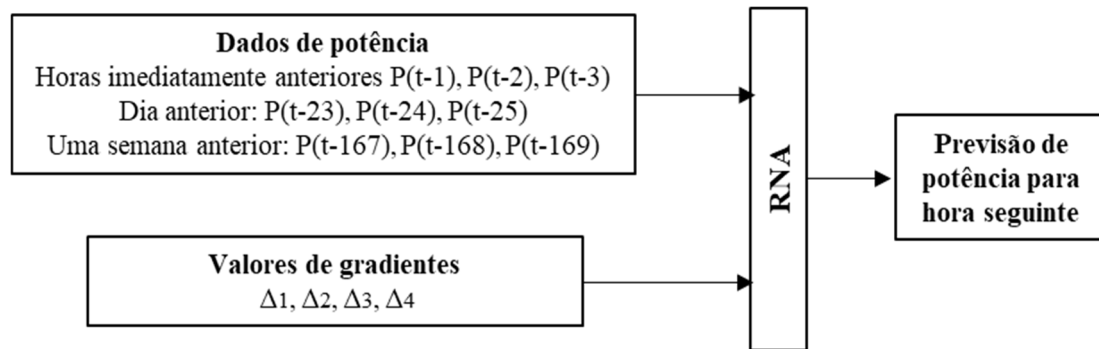


Figura 5-2: Vector de entrada final, composição simples.

As variáveis de entrada estão organizadas por blocos distintos, conforme os seus tipos.

As variáveis $P(t-1)$, $P(t-2)$... $P(t-n)$ são os valores de potência com atraso de n horas usados na construção do vector de entrada. Como foi demonstrado em (Santos, Previsão de cargas em horizonte de curto-prazo aplicada a subestações de distribuição, 2005), as sequências contíguas demasiado extensas não contribuem para melhorar o desempenho do modelo de previsão, apenas conduzindo à sua sobre parametrização. Esse estudo foi baseado na evolução dos valores de entropia, nomeadamente na medição de entropia da amostra (*Sample Entropy – SampEn*).

Os valores homólogos relativos ao dia anterior da previsão e à semana anterior, juntamente com os valores adjacentes, foram incluídos no vector de entrada, depois de realizada a análise de coeficientes de autocorrelação, descrito no capítulo 4.

Os valores de potência obtidos nas três horas anteriores à hora da previsão, no dia anterior e na semana anterior de previsão, juntamente com os respectivos gradientes, estão esquematicamente representados na figura 5-3. Este diagrama mostra as variáveis endógenas que compõem o vetor de entrada, no caso da previsão para as 6 horas da manhã.

Nesta ilustração, $P(t-1)$, $P(t-2)$ e $P(t-3)$ são os valores das variáveis registados em instantes anteriores ao momento da previsão. Foi verificado que as sequências de

valores contíguas mais extensas em nada contribuem para o bom desempenho do modelo de previsão para a hora seguinte. $P(t-24)$ e $P(t-168)$ são os valores de desfasamento correspondentes a um dia e a uma semana relativamente à hora de previsão. $P(t-23)$ e $P(t-25)$, $P(t-167)$ e $P(t-169)$ são os valores adjacentes dos valores desfasados de um dia e de uma semana, respectivamente.

Quanto ao gradiente, ele mostra pelo seu sinal o crescimento ou decrescimento da função. A função no nosso caso é a evolução temporal de diagrama de carga.

O gradiente Δ_i calcula-se pela diferença entre os valores de cargas adjacentes $P(t-k)$, $P(t-k+1)$ em que k é o deslocamento para trás, por exemplo: $\Delta_1 = P(t-23) - P(t-24)$, $\Delta_2 = P(t-24) - P(t-25)$, etc.




Figura 5-3: Variáveis de potências e gradientes que fazem parte do vector de entrada inicial.

A figura 5-4 ilustra a constituição do vector de entrada que inclui não só os valores de potências e gradientes descritos anteriormente, mas também os valores dos patamares, e o sinal aleatório.

Pela analogia com a figura 5-2, as variáveis de entrada também estão organizadas por blocos distintos, conforme os seus tipos: os dados de potência activa, os valores de gradientes, os valores de patamares, os tipos de dia, as estações do ano, o sinal aleatório.

O objectivo da introdução dos patamares e do sinal aleatório é o de aumentar o rigor da previsão, propriedade que se pretende testar e confirmar com as simulações realizadas, com várias alternativas de composição.

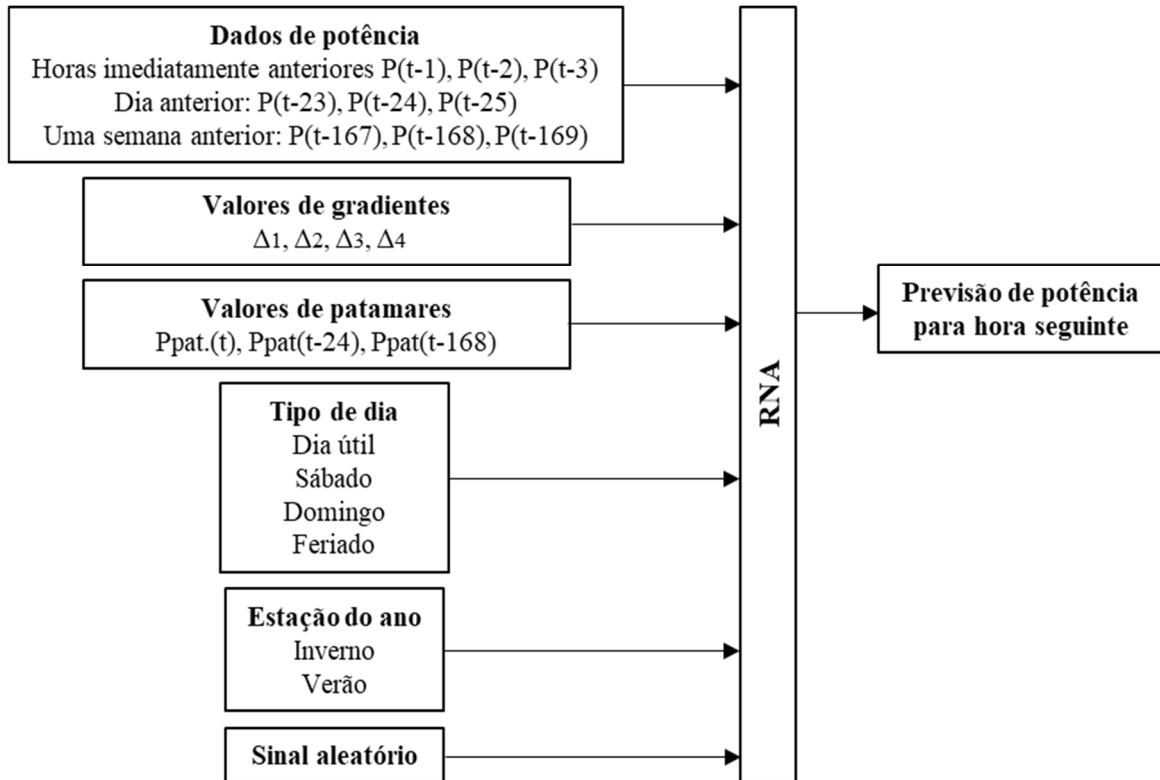


Figura 5-4: Vector de entrada final, com patamares e sinal aleatório.

Após o treino e simulação do modelo de previsão para a hora seguinte, com consideração das três variáveis endógenas contíguas $P(t-1)$, $P(t-2)$ e $P(t-3)$, gradientes, patamares de carga e sinal aleatório, chegou-se à conclusão que os indicadores estatísticos usados na avaliação do desempenho do método (nomeadamente, MAPE) apresentavam pequenas melhorias, na ordem das centésimas ou até milésimas (Tabela 5-2). Embora não constitua grande progresso no desempenho do modelo, pode ser importante em algumas situações do comportamento de rede de energia eléctrica, por exemplo, na altura de reconfigurações da rede ou de funcionamento em regime de sobrecarga.

Tabela 5-2: Os valores de MAPE obtidos para a previsão para a hora seguinte.

Vector de Entrada	Lisboa	Porto	Évora
1 - Simples	0,723	1,043	1,173
2 - Com patamares e sinal aleatório	0,704	1,042	1,136

Alguns resultados de simulação obtidos são apresentados nas figuras 5-5 - 5-8 na forma gráfica, onde os dados reais são representados pela cor azul (obtidos a partir da leitura de telemetria) e os de previsão, pela cor vermelha.

As figuras 5-5 e 5-6 ilustram os diagramas de carga do dia 4 de Fevereiro de 2014, das subestações de Évora e Porto. Não é por acaso que o dia 4 de Fevereiro de 2014 foi escolhido: na base de dados de EDP esse dia foi registado como o dia de maior consumo em 2014.




Figura 5-5: Diagrama de carga real e previsto, cidade de Évora.

A forma das curvas de diagramas de carga é diferente, porque os tipos de padrão de carga são diferentes. No diagrama de carga de Évora existe apenas uma ponta, mas no diagrama de carga do Porto já aparecem duas pontas. A análise destas curvas mostra que o padrão de carga de subestações de Évora é mais residencial, mas no Porto a parte de consumo comercial e industrial já se torna significativa.




Figura 5-6: Diagrama de carga real e previsto, cidade do Porto.

As figuras 5-7 e 5-8 representam os diagramas de carga semanais obtidas, correspondentes a 3-9 de Fevereiro de 2014, para as mesmas cidades. Em ambos os gráficos se observa a ponta na terça-feira 4 de Fevereiro, é o segundo diagrama de carga à esquerda.




Figura 5-7: Diagramas de carga no período de uma semana, cidade de Évora.




Figura 5-8: Diagramas de carga no período de uma semana, cidade do Porto.

As tabelas 5-3 e 5-4 representam dois indicadores de erro mais significativas: o valor máximo de PE_t e $MAPE$ para os casos de estudo correspondentes a carga das subestações de Évora e do Porto. O período em análise é o dia 4 de Fevereiro de 2014 e uma semana de 3 até 9 de Fevereiro de 2014. Os resultados são satisfatórios, considerando que o valor máximo de $MAPE$ nos estudos de previsão deste tipo não deve exceder 5%.

Tabela 5-3: Análise do erro de previsão das subestações do Porto.

Período	Max $ PE_t $ (%)	MAPE (%)
Um dia	2,30	0,78
Uma semana	4,90	1,01

Tabela 5-4: Análise do erro de previsão das subestações de Évora.

Período	Max $ PE_t $ (%)	MAPE (%)
Um dia	3,70	0,82
Uma semana	3,95	0,88

A figura 5-9 ilustra como exemplo da evolução de percentagem de erro para o período de duas semanas, de 3 até 16 de Fevereiro 2014, nas subestações de Évora.




Figura 5-9: Percentagem de erro no período de duas semanas.

Relativamente à análise de erro aplicada à potência máxima (ponta) do diagrama de carga da cidade de Évora, observa-se que esta ocorreu em 21 de Janeiro de 2014 às 20:00. O PE_t naquele momento é pequeno: 0,7%. Para a cidade do Porto, a ponta foi registada em 4 de Fevereiro às 13:00 com PE_t igual a 3,7%.

O MAPE de 10 registos destas duas cidades com cargas mais elevadas do mesmo ano em Évora é de 0,94%, e no Porto - 1.52%. Como os indicadores estatísticos de erros ainda permanecem abaixo de 5%, os resultados do modelo de previsão continuam satisfatórios.

5.3 PREVISÃO PARA 24 HORAS SEGUINTES

A previsão para a hora seguinte tem utilidade limitada, servindo para o propósito de operação da rede em tempo real, por exemplo, em caso de restabelecimento pós-avaria. Para efeitos de actuação em mercado, ou de aplicação de medidas de gestão da procura (DSM), requerem-se previsões com maior antecedência, 24 ou 48 horas. Por esse

motivo considerou-se importante avaliar o método proposto na realização de previsões para o dia seguinte.

Figura 5-10 ilustra o esquema geral de previsão de potência para o dia seguinte, ou seja, para cada das 24 horas do próximo dia.




Figura 5-10: Esquema geral do modelo de previsão para o dia seguinte.

Para aferir a eficácia da metodologia proposta para a previsão de 24 horas seguintes, foram efectuadas simulações de previsão para o ano 2015, com base nos dados de 2014 para o vector de entrada, para os três casos de estudo. Os resultados, avaliados pelo indicador MAPE para várias composições de vector de entrada, encontram-se na tabela 5-5.

Na legenda da tabela, “patamares” significa que o vector de entrada inclui os valores de patamares do diagrama de patamares obtido para o diagrama de carga de potência média da época correspondente, do ano 2014 (Inverno, Primavera, Verão ou Outono). Na mesma legenda, “patamares + desfasamentos” significa que o vector de entrada inclui não só os valores dos patamares da hora de previsão, mas também os valores desfasados em 24 horas (1 dia) e em 168 horas (1 semana). “Sinal aleatório” significa que no vector de entrada, ao valor do patamar na hora da previsão, é acrescentado ainda o valor de sinal aleatório. O significado das abreviaturas de estações do ano: I,V – Inverno, Verão; I, P, V, O - Inverno, Primavera, Verão, Outono.

Tabela 5-5: MAPE – previsão do dia seguinte

Vector de Entrada	Nº da previsão	Lisboa		Porto		Évora	
Simples	1	4,146		4,324		5,303	
Com patamares		I,V	I,P,V,O	I,V	I,P,V,O	I,V	I,P,V,O
Patamares	2 e 3	3,189	3,465	3,393	3,490	4,998	4,931
Patamares + desfasamentos	4 e 5	2,759	2,948	3,229	3,092	3,728	4,023
Com patamares e sinal aleatório							
Patamares	6 e 7	3,290	3,692	3,499	3,298	3,954	4,800
Patamares + desfasamentos	8 e 9	2,655	3,008	3,002	2,986	3,955	4,221

Os números de previsão pares (2, 4, 6, 8) correspondem às duas épocas do ano: Inverno e Verão. Os números ímpares (3, 5, 7, 9) – às quatro épocas do ano: Inverno, Primavera, Verão, Outono.

Designação de previsões da tabela ensaiados conforme o número de patamares e épocas de ano, (onde VE significa o vector de entrada para treino de RNA):

1 – simples, sem patamares e sem sinal aleatório. $VE = [P(t-24), P(t-168)]$

2 – com patamares; Inverno, Verão. $VE = [P_{PAT\ I,V}(t), P(t-23), P(t-24), P(t-25), P(t-167), P(t-168), P(t-169)]$

3 – com patamares; Inverno, Primavera, Verão, Outono. $VE = [P_{PAT\ I,P,V,O}(t), P(t-23), P(t-24), P(t-25), P(t-167), P(t-168), P(t-169)]$

4 – com patamares e séries desfasadas dos patamares (1 dia e 1 semana); Inverno, Verão. $VE = [P_{PAT\ I,V}(t), P_{PAT\ I,V}(t-24), P(t-23), P(t-24), P(t-25), P_{PAT\ I,V}(t-168), P(t-167), P(t-168), P(t-169)]$

5 – com patamares e séries desfasadas dos patamares (1 dia e 1 semana); Inverno, Primavera, Verão, Outono. $VE = [P_{PAT\ I,P,V,O}(t), P_{PAT\ I,P,V,O}(t-24), P(t-23), P(t-24), P(t-25), P_{PAT\ I,P,V,O}(t-168), P(t-167), P(t-168), P(t-169)]$

6 – com patamares + sinal aleatório; Inverno, Verão. $VE = [P_{PAT\ I,V}(t), P(t-23), P(t-24), P(t-25), P(t-167), P(t-168), P(t-169), P_{RANDOM}(t)]$

7 – com patamares + sinal aleatório; Inverno, Primavera, Verão, Outono. $VE = [P_{PAT\ I,P,V,O}(t), P(t-23), P(t-24), P(t-25), P(t-167), P(t-168), P(t-169), P_{RANDOM}(t)]$

8 – com patamares e séries desfasadas dos patamares (1 dia e 1 semana) + sinal aleatório; Inverno, Verão. $VE = [P_{PAT\ I,V}(t), P_{PAT\ I,V}(t-24), P(t-23), P(t-24), P(t-25), P_{PAT\ I,V}(t-168), P(t-167), P(t-168), P(t-169), P_{RANDOM}(t)]$

9 – com patamares e séries desfasadas dos patamares (1 dia e 1 semana) + sinal aleatório; Inverno, Primavera, Verão, Outono. $VE = [P_{PAT\ I,P,V,O}(t), P_{PAT\ I,P,V,O}(t-24), P(t-23), P(t-24), P(t-25), P_{PAT\ I,P,V,O}(t-168), P(t-167), P(t-168), P(t-169), P_{RANDOM}(t)]$

Após a análise descrita anteriormente para o modelo de previsão de dia seguinte, foi definido o vector de entrada final como representado na figura 5-11, que corresponde à previsão nº 9 e que obteve o melhor resultado na avaliação quantitativa do erro médio de previsão (MAPE). Como já foi assinalado antes, o vetor de entrada do modelo de previsão não inclui as variáveis exógenas (temperatura do ar, humidade do ar, velocidade do vento e nebulosidade) porque a correlação entre estas variáveis e as variáveis endógenas é fraca.

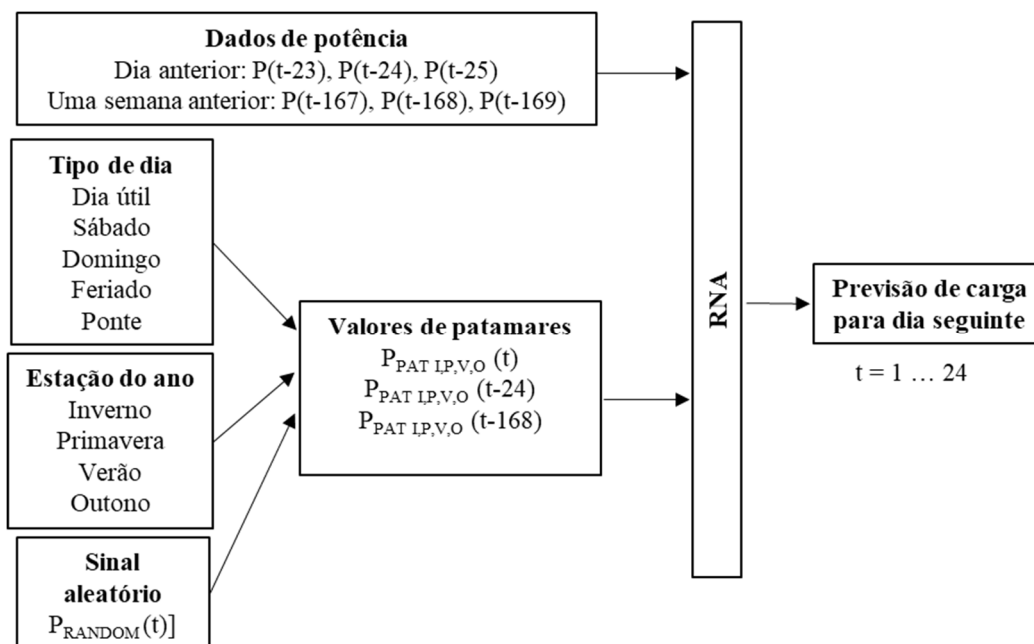


Figura 5-11: Composição do vector de entrada final para a previsão de carga para o dia seguinte.

As variáveis endógenas do vector de entrada $P(t-23)$, $P(t-24)$... $P(t-169)$ são os valores de carga registada (potência activa). P_{PAT} é a variável correspondente ao patamar de perfil de carga dada estação do ano e do tipo de dia de semana. P_{RANDOM} é o valor do sinal aleatório que oscila em torno de cada patamar.

Na previsão do dia seguinte, ao contrário da previsão para a hora seguinte, o desempenho do modelo proposto torna-se notável (Tabela 5-5). Desta forma se demonstra a mais valia do vector de entrada enriquecido, conforme descrito neste trabalho.

Da observação dos resultados verifica-se que se obtêm melhorias progressivas quando são introduzidos no vector de entrada as variáveis dos patamares de carga. Nota-se uma redução significativa do erro de previsão, quando passamos a usar séries desfasadas dos patamares (1 dia e 1 semana) em vez de só usar as séries dos patamares directas (relativos à hora de previsão) no vector de entrada. A diversificação progressiva dos patamares pelas épocas do ano, de duas para quatro, não trouxe melhoria consistente na previsão, havendo casos onde o resultado da previsão até piorou. A adição do sinal aleatório no diagrama dos patamares em muitos casos deu resultado positivo.

Em geral, os resultados representados na tabela 5-5 são bastante satisfatórios, porque o valor de MAPE (o mais usado indicador estatístico nos estudos de previsão tanto para o dia seguinte como para a hora seguinte) não deve exceder 5% (Hippert, Pedreira, & Sousa, 2001), (Santos, Martins, & Pires, Designing the input vector to ANN-based models for short-term load forecast in electricity distribution systems, 2007).

Foram também testadas as variáveis associadas aos gradientes Δ_i , descritos anteriormente no subcapítulo 5.2. Infelizmente não se verificou melhoria significativa no desempenho das RNA. Assim, a inclusão de gradientes no vector de entrada só teve vantagem para a previsão da hora seguinte, mas não para a previsão do dia seguinte.

Nas figuras 5-12 e 5-13 apresentam-se alguns exemplos dos resultados de simulação na forma gráfica.

A figura 5-12 representa os diagramas de carga de um dia útil de Inverno, 15/12/2015, no caso de Lisboa. Um dos gráficos representa o diagrama real obtido através do sistema de contagem e os outros dois gráficos foram obtidos com o sistema de previsão desenvolvido, considerando o vector de entrada simples e o vector de

entrada que incluiu as variáveis de patamar e de sinal aleatório (correspondente a previsão 9). Para não sobrecarregar a leitura do gráfico, foram representados só os resultados mais significativos desta previsão, mas na tabela 5-6 lêem-se os valores de MAPE para esse dia, correspondentes às nove composições do vector de entrada.




Figura 5-12: Resultados de previsão para um dia de Inverno, 15.12.2015, Lisboa.

Tabela 5-6: Os parâmetros de MAPE para cada tipo de previsão efectuada.

Previsão	1	2	3	4	5	6	7	8	9
MAPE	8,596%	3,591%	4,291%	3,198%	3,603%	3,706%	3,552%	3,419%	3,282%

A figura 5-13 e a tabela 5-7 ilustram os resultados de previsão para um dia de Verão, 30.06.2015, no caso de Lisboa. Nestes dois exemplos apresentados são visíveis as melhorias introduzidas pela inclusão dos patamares e do sinal aleatório no vector de entrada das RNA.




Figura 5-13: Resultados de previsão para um dia de Verão, 30.06.2015, Lisboa.

Tabela 5-7: Os parâmetros de MAPE para cada tipo de previsão efectuada

Previsão	1	2	3	4	5	6	7	8	9
MAPE	5,560%	2,872%	4,708%	2,619%	2,378%	3,843%	3,102%	3,658%	2,552%

Os resultados de previsão para uma semana de Verão, 13/06/2015 – 19/06/2015, cidade de Lisboa, estão ilustrados pelas figuras 5-14 e 5-15. O gráfico na figura 5-14 mostra o diagrama semanal real e previsto, e o na figura 5-15 – a evolução de percentagem de erro (PE) para o mesmo período de tempo. O indicador de MAPE para a previsão da carga nesta semana é 2,261%, valor este que está em linha com a precisão adequada para este tipo de previsões (Hippert, Pedreira, & Sousa, 2001), (Lourenço & Santos, 2012). Nota-se a tendência de errar por defeito na previsão de carga desta semana.




Figura 5-14: Resultados de previsão para uma semana de Verão, 13-19 de Junho de 2015, Lisboa.




Figura 5-15: Evolução da percentagem de erro para a previsão apresentada na figura 5-14.

Como exemplo da evolução da percentagem de erro, representa-se o gráfico na figura 5-16, correspondente à época de Inverno, de 14 a 27 de Dezembro de 2015, no caso de estudo da cidade de Lisboa. O valor mais alto observa-se no dia 19 de Dezembro, sábado. Provavelmente, este erro pode ser explicado pelo facto da aproximação da época de Natal, quando muitos estabelecimentos comerciais estão abertos até hora muito tardia. O nosso modelo de previsão conta com fins-de-semana e dias especiais, como férias e pontes. Mas os dias como os do gráfico e alguns outros (por exemplo, campeonatos de futebol, greves) não estão considerados no modelo. No entanto, dispondo de informação de cargas estatisticamente significativa, poderia ser criado um tipo de dia especial para eventos desta natureza, introduzindo os respectivos patamares.




Figura 5-16: Percentagem de erro para 10 dias de Inverno: 14.12 – 27.12 2015, Lisboa.

Na figura 5-17 é dado outro exemplo da evolução da percentagem de erro, agora para outra época de ano e outra zona de Portugal: de 15 a 24 de Junho, cidade de Évora.




Figura 5-17: Percentagem de erro para 10 dias de Verão: 15.06 – 24.06 2015, Évora.

Na figura 5-18 encontra-se mais um exemplo de previsão, acompanhado com o gráfico de evolução de percentagem de erro (figura 5-19) que novamente espelha o grau de aproximação do modelo de previsão desenvolvido. O período de tempo representado é o mês de Julho de 2015, local - cidade de Lisboa.




Figura 5-18: Resultados de previsão para um mês de Verão, Julho de 2015, Lisboa.




Figura 5-19: Evolução da percentagem de erro para a previsão apresentada na figura 5-18.

Alguns indicadores estatísticos relevantes do erro de previsão, tais como MAPE, MPE, RMPSE são representados na tabela 5-8 para os três casos de estudo seleccionados. Esses indicadores estatísticos referem-se à simulação com melhores resultados para cada caso e que foi a designada como Previsão 9. O vector de entrada de RNA correspondente está representado na figura 5-11 e caracteriza-se com a seguinte expressão: $VE = [P_{PAT\ LP,V,O}(t), P_{PAT\ LP,V,O}(t-24), P(t-23), P(t-24), P(t-25), P_{PAT\ LP,V,O}(t-168), P(t-167), P(t-168), P(t-169), P_{RANDOM}(t)]$.

Tabela 5-8: MAPE, MPE e RMSPE para três casos de estudo.

	Lisboa	Porto	Évora
MPE (%)	-0.520	-0.123	-0.387
MAPE (%)	3.692	3.002	3.955
RMSPE (%)	5.128	4.182	5.434

Os resultados obtidos são satisfatórios, comparáveis com os publicados na literatura sobre esta área (Kaytez, Taplamacioglu, Cam, & Hardalac, 2015), (Zor, Timur, & Teke,

2017), comprovando bom desempenho da nova abordagem proposta relativamente a composição do vector de entrada do modelo previsor.

A medida do erro relativa ou percentual torna-se necessária para comparação da precisão entre vários métodos e casos de estudo que podem basear-se em diferentes séries temporais ou intervalos de tempo.

O indicador estatístico mais utilizado na bibliografia é o MAPE (Hippert, Pedreira, & Sousa, 2001), que conjuntamente com o RMSPE, vai ser utilizado para a comparação.

Embora seja muito difícil a reprodução dos modelos de outras abordagens, foram efectuadas comparações com outras metodologias com base em indicadores estatísticos e tipo de metodologia.

Após consulta de fontes bibliográficas no campo de previsão de carga em curto prazo foram criadas as tabelas comparativas (tabelas 5-9 e 5-10). Em ambas as tabelas, a primeira alínea refere-se à fonte bibliográfica, e a segunda – ao método utilizado. Como o motor do nosso modelo previsor é uma RNA, resolveu-se comparar primeiro os resultados de previsão entre modelos que utilizam também as redes neuronais (tabela 5-9). A validação de cada rede neuronal foi realizada com base na fase de testes, embora haja autores que apresentam também os erros na fase de treinos. Já a tabela 5-10 destina-se a comparar com os erros de previsão dos métodos diferentes de RNA (tradicionais e os de inteligência artificial), usados pelos autores dos trabalhos encontrados através de pesquisa bibliográfica.

Designações das redes neuronais estudadas para o efeito de comparação de resultados (tabela 5-9):

ANN – Artificial Neural Network, FFNN – Feed Forward Neural Network, RNN – Recurrent Neural Network, NARX – Neural Network-based nonlinear autoregressive exogenous model, SNN – Shallow Neural Network e duas diferentes Deep Neural Networks (DNN): RBM – Restricted Boltzmann Machine pre-training method e ReLU – DNN with rectified linear unit. DNN é ANN com mais camadas comparando com três típicas camadas de MLP.

Os dois últimos modelos apresentaram os menores erros MAPE e RMSPE, embora outros modelos também foram considerados satisfatórios.

Os valores de erros do nosso modelo estão entre os valores mínimos e máximos desta tabela o que mostra a aceitabilidade do método proposto.

Em relação aos métodos indicados na tabela 5-10 foram usadas as seguintes abreviaturas:

CGP – Cartesian Genetic Programming, ANFIS – Adaptive Neuro-Fuzzy Inference System, ARIMA - Autoregressive Integrated Moving Average, SVM - Support Vector Machine, DSHW – Double Seasonal Holt-Winters, MLR - Multiple Linear Regression.

O campo desta tabela correspondente ao valor de RMSPE não preenchido significa que este não foi divulgado pelos autores na apresentação dos seus resultados.

Tabela 5-9: Comparação de indicadores de erro MAPE e RMSPE obtidos com outros modelos de previsão baseados em redes neuronais.

Estudo	[1]	[2]	[2]	[2]	[3]	[4]	[4]	[4]
Método	ANN	FFNN	RNN	NARX	ANN	SNN	RBM	ReLU
MAPE	4,96	8,71	6,98	4,01	2,50	2,98	2,27	2,19
RMSPE	6,76	14,81	9,8	6,86	2,95	3,70	2,91	2,76

Tabela 5-10: Comparação de indicadores de erro MAPE e RMSPE obtidos com outros modelos de previsão diferentes de redes neuronais.

Estudo	[4]	[5]	[6]	[7]	[7]	[8]	[8]	[9]
Método	DSHW	ARIMA	MLR	ARX-24	Wavelet	CGP	ANFIS	SVM
MAPE	2,55	3,42	4,67	7,2	8,1	4,13	4,32	8,13
RMSPE	3,35	4,47	-	-	-	3,94	4,9	11,57

Para facilitar a leitura das tabelas, as fontes bibliográficas dos estudos que serviram para a apresentação comparativa dos erros de previsão (primeira alínea em ambas as tabelas), encontram-se enumeradas de maneira seguinte: 1 - (Sousa, Neves, & Jorge, 2012); 2 - (Park, Lee, Son, & Ahn, 2017); 3 - (López, Valero, Rodriguez, Veiras, & Senabre, 2018); 4 - (Ryu, Noh, & Kim, 2017); 5 – (Rodygina & Rodygin, 2016); 6 - (Cheepati & Prasad, 2016); 7 - (Høverstad, Tidemann, Langseth, & Öztürk, 2015); 8 -

(Giacometto, Sala, Kampouropoulos, & Romeral, 2015); 9 - (Huang, Guo, Yang, & Xu, 2017).

Na maior parte dos casos apresentados nas tabelas 5-9 e 5-10 obtiveram-se valores de MAPE entre 2,5% e 5%, o que está dentro dos valores admitidos pelo operador.

Alguns métodos baseados nas redes neuronais, dentro dos quais podemos mencionar o método proposto, apresentam valores de erros mais baixos ou da mesma ordem de grandeza, comparativamente com os valores obtidos por outros métodos.

Os valores de erros, MAPE e RMSPE, do método proposto estão entre os valores dos outros métodos representados nestas tabelas, que foram também considerados satisfatórios pelas respectivas publicações.

Foi também realizada uma comparação de resultados, usando o método de previsão desenvolvido, onde os patamares de carga tiveram largura temporal igual aos períodos tarifários em vigor em Portugal, constituídos por horas de ponta, cheias, de vazio e de super-vazio. Verificou-se que os resultados da previsão pioraram, ultrapassando o valor considerado aceitável de MAPE de 5%. Este resultado indica que duração dos períodos tarifários possa estar desajustada da realidade. Confirma-se que a optimização da duração dos patamares em função do diagrama real médio diário das cargas, conforme executado no método proposto, conduz a melhores resultados da previsão.

5.4 REDE NACIONAL DE TRANSPORTE COMO MAIS UM CASO DE ESTUDO

O modelo de previsão para 24 horas seguintes foi também testado com os dados de carga de Rede Nacional de Transporte (RNT), cujo mapa da topologia das redes de Muito Alta Tensão (400, 220 e 150 kV) está ilustrado pela figura 5-20.

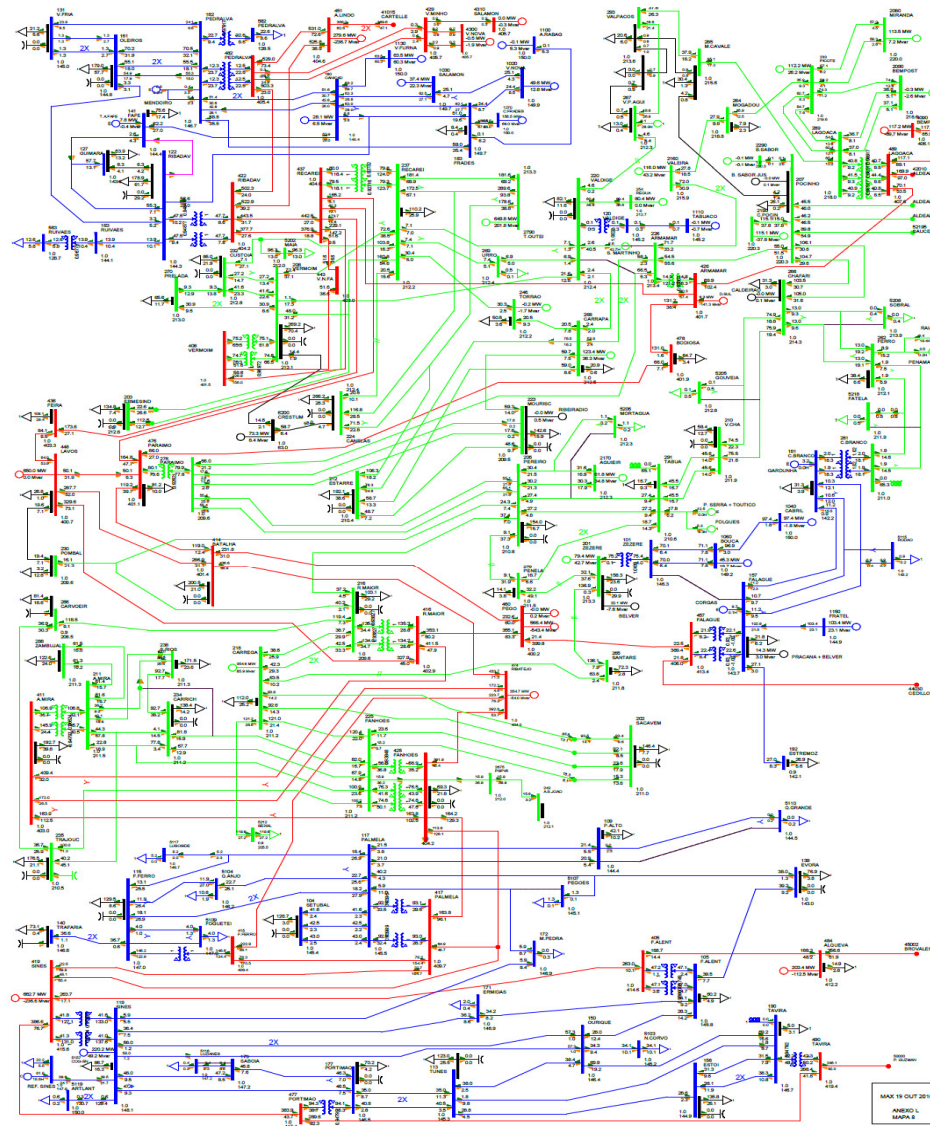


Figura 5-20: Esquema de ligações de RNT. Obtido de (REN, 2017).

Os resultados obtidos pelo modelo proposto para a previsão de carga eléctrica de curto prazo (24 horas seguintes), referentes aos vários períodos do ano 2015, estão apresentados graficamente nas figuras 5-21 – 5-27. Para uma melhor leitura e interpretação dos resultados, os gráficos de evolução de erros de previsão encontram-se logo a seguir aos gráficos das curvas de carga real e prevista.

O maior consumo na época quente normalmente acontece à tarde (figura 5-21, dia 28 de Maio de 2015), o que pode ser explicado pelo uso de equipamentos de climatização – ar condicionado. Nesse dia a carga prevista é inferior à carga real o que não é muito favorável para os operadores de sistemas de energia eléctrica. A tendência de errar por

defeito na previsão de carga não é mais prudente sob o ponto de vista de segurança do sistema.

Na figura 5-22 está apresentada a evolução do indicador de percentagem de erro para o mesmo dia. O valor mais alto de erro observa-se por volta de meio-dia (quase 3%), seguido o erro nas horas de ponta (2,4-2,5%). MAPE diário é igual a 1,73% o que é bastante bom para este tipo de previsões.




Figura 5-21: Diagrama de carga real e previsto para 28 de Maio de 2015.




Figura 5-22: Evolução da percentagem de erro para 28 de Maio de 2015.

Os resultados de previsão semanal com os erros correspondentes (neste exemplo é uma semana 9-15 de Fevereiro de 2015) são apresentados nas figuras 5-23 – 5-25. Nota-se a hora de ponta ser deslocada mais para o fim do dia (20-21h.), altura quando se usam mais equipamentos elétricos de aquecimento nesta época fria. Observa-se também a diminuição de consumo de energia elétrica no fim de semana, o que é normal para qualquer época de ano.




Figura 5-23: Diagrama de carga real e previsto para semana 9-15 de Fevereiro de 2015.




Figura 5-24: Evolução da percentagem de erro para semana 9-15 de Fevereiro de 2015.




Figura 5-25: MAPE para cada dia de semana 9-15 de Fevereiro de 2015.

O indicador de MAPE para a previsão da carga nesta semana é 2,31%. Relativamente a MAPE's calculados para cada dia de semana observa-se que o maior valor foi atingido na terça feira e os menores valores – na quinta feira e na sexta feira.

O diagrama de carga mensal (Outubro 2015) real e previsto com os respectivos erros de previsão horários e MAPE total são ilustrados nas figuras 5-26 e 5-27. Nota-se a tendência de errar por excesso na previsão de carga deste mês.

O valor de MAPE cometido nesse período mensal foi de apenas 2,1%, mostrando um bom ajuste.




Figura 5-26: Diagrama de carga real e previsto para o mês de Outubro de 2015.




Figura 5-27: Evolução da percentagem de erro para o mês de Outubro de 2015.

5.5 CONCLUSÕES

Os resultados apresentados validam o modelo computacional de previsão de carga proposto, baseado nas RNA. Nesta validação o modelo foi submetido a duas análises, com e sem inclusão no vector de entrada os valores de patamares de carga, as quais concluíram quão robusta e precisa é a resposta do modelo. Outro ponto de interesse consiste em verificar quão genérica pode ser a aplicação do modelo para diferentes configurações do diagrama de cargas. Esta avaliação é realizada, analisando a resposta do método em diferentes cenários: três casos de estudo, correspondentes aos diagramas de carga das cidades de Lisboa, de Évora e do Porto, e ainda o diagrama de consumo da RNT. Verifica-se que se mantém o mesmo nível de desempenho nos diferentes cenários, confirmando a aplicabilidade generalizada do método apresentado neste trabalho.

A inovação do método assenta na composição do vector de entrada. O vector de entrada, com recurso ao diagrama de patamares, por estação do ano e tipo de dia da semana, corresponde a uma inovação neste tipo de modelos. A inclusão de um sinal aleatório, adicionado ao perfil de carga introduz uma aleatoriedade acrescentado a tendência, faz com que o vector de entrada se mantenha simples e robusto para os diferentes casos de estudo.

Alguns outros aspectos de previsão de carga em redes de média tensão, como a ampliação do horizonte de previsão, o algoritmo de aprendizagem etc. serão realizados em trabalhos futuros.

Previsão das pontas diárias do diagrama de carga

Neste capítulo procede-se à descrição e análise dos resultados dos ensaios de aplicação do método proposto à previsão das pontas diárias de consumos.

6.1 INTRODUÇÃO

A previsão da ponta de carga eléctrica é um processo indispensável para o planeamento e operação dos sistemas de energia eléctrica. Representa também um factor de vantagem na gestão das empresas que participam no mercado de energia, permitindo uma gestão mais eficiente e económica do fornecimento de energia eléctrica. Nomeadamente, as pontas de carga têm cada vez mais impacto nos custos das redes de transporte e de distribuição de energia eléctrica, que têm de assegurar o abastecimento dos consumos, com o grau exigido de fiabilidade, por obrigação regulatória.

Todos os agentes do mercado de energia têm interesse na previsão de cargas, desde os produtores, para programarem o mix de produção e gerir as suas ofertas, aos comercializadores, para aprovisionarem as quantidades horárias de energia. Fruto da maior variabilidade e intermitência das fontes cada vez mais utilizadas na produção de energia eléctrica, as variações de preços ao longo do dia e das estações do ano são maiores.

O mercado diário do MIBEL é a plataforma ibérica onde se transacciona a energia eléctrica para entrega no dia seguinte. Este mercado forma um preço para cada uma das 24 horas do dia seguinte através do cruzamento de ofertas, de compra e venda, por parte dos diversos agentes comercializadores grossistas (OMIE, 2015).

A figura 6-1 mostra a variação do preço da energia eléctrica no mercado diário do MIBEL (para Portugal), verificada no dia 21/01/2015.




Figura 6-1: Evolução do preço da energia eléctrica do mercado diário para Portugal, dia 21/01/2015. Obtido de (OMIE, 2015).

O Gestor do Sistema (GS) realiza diariamente um conjunto de previsões de consumo nos diversos horizontes temporais, relativo ao Sistema Eléctrico Nacional, que são disponibilizadas aos Agentes de Mercado e ao Operador de Mercado. Entre outras disposições, o “Manual de procedimentos do Gestor do Sistema” estabelece que o GS elaborará e publicará uma previsão do consumo diário até às 17h do dia anterior, incluindo essa previsão o horizonte temporal das vinte e quatro horas do dia ‘d+2’ (ERSE, 2009). A previsão diária, é actualizada noventa minutos antes do fecho de cada sessão do mercado diário ou intra-diário, para o horizonte adequado. Como exemplo desta previsão diária, representa-se na figura 6-2 o diagrama de carga real que se refere ao dia 15 de Outubro de 2015, elaborado com base na estatística diária do SEN (REN, 2016).




Figura 6-2: Diagrama de carga real e prevista, 2015-10-15, Portugal.

São notórias as diferenças entre a previsão do consumo e o consumo real, na figura às 20h a diferença entre o valor verificado e a previsão registou-se num diferencial de cerca 270 MW que foi objecto de despacho não programado, muito dependente da produção do momento. Este diferencial teve custos adicionais para o sistema. O preço de energia eléctrica varia durante o dia (Figura 6-3, elaborado a partir da informação do mercado (OMIE, 2015)). Da base de dados estatísticos de MIBEL tira-se o preço médio diário de energia eléctrica no mês de Outubro de 2015 - 50 €/MWh, e no dia 15 de Outubro - 54 €/MWh (OMIE, 2015). Assim, o erro de previsão na hora de ponta, das 20h. até às 21h., grosso modo, pode avaliar-se em 14580 €. Torna-se importante para o

GS disponibilizar a informação da previsão de carga precisa e de confiança, para os Agentes do Mercado poderem tomar as decisões importantes na sua actividade.




Figura 6-3: Evolução de preços médios diários durante o mês de Outubro do ano 2015, Portugal.

Como exemplo ilustrativo de distribuição de potência produzida por fontes energéticas no dia 15 de Outubro de 2015 (já referido em cima), na figura 6-4 encontra-se o diagrama de carga real com a indicação de fontes em jogo (REN, 2015).




Figura 6-4: Distribuição de potência produzida por fontes, 2015-10-15, Portugal.

6.2 RESULTADOS DE PREVISÃO DA PONTA DIÁRIA DO DIAGRAMA DE CARGA

Baseando-se na análise do modelo predictor efectuada no capítulo 5, optou-se por treinar e simular a rede com o objectivo de prever as potências máximas (pontas) diárias do diagrama de cargas.

A estrutura de vector de entrada (VE) de RNA é idêntico à já descrita anteriormente, mas neste estudo os números de previsões 6 e 7 correspondem às 8 e 9 do subcapítulo 5.3. Esta eliminação de duas variantes de VE surgiu por causa de não haver melhoria significativa com o uso destes.

Para a facilidade de leitura colocam-se aqui as variantes de VE considerados:

- 1 – simples, sem patamares e sem sinal aleatório. $VE = [P(t-24), P(t-168)]$
- 2 – com patamares; Inverno, Verão. $VE = [P_{PAT\ I,V}(t), P(t-23), P(t-24), P(t-25), P(t-167), P(t-168), P(t-169)]$
- 3 – com patamares; Inverno, Primavera, Verão, Outono. $VE = [P_{PAT\ I,P,V,O}(t), P(t-23), P(t-24), P(t-25), P(t-167), P(t-168), P(t-169)]$
- 4 – com patamares e séries desfasadas dos patamares (1 dia e 1 semana); Inverno, Verão. $VE = [P_{PAT\ I,V}(t), P_{PAT\ I,V}(t-24), P(t-23), P(t-24), P(t-25), P_{PAT\ I,V}(t-168), P(t-167), P(t-168), P(t-169)]$
- 5 – com patamares e séries desfasadas dos patamares (1 dia e 1 semana); Inverno, Primavera, Verão, Outono. $VE = [P_{PAT\ I,P,V,O}(t), P_{PAT\ I,P,V,O}(t-24), P(t-23), P(t-24), P(t-25), P_{PAT\ I,P,V,O}(t-168), P(t-167), P(t-168), P(t-169)]$
- 6 – com patamares e séries desfasadas dos patamares (1 dia e 1 semana) + sinal aleatório; Inverno, Verão. $VE = [P_{PAT\ I,V}(t), P_{PAT\ I,V}(t-24), P(t-23), P(t-24), P(t-25), P_{PAT\ I,V}(t-168), P(t-167), P(t-168), P(t-169), P_{RANDOM}(t)]$
- 7 – com patamares e séries desfasadas dos patamares (1 dia e 1 semana) + sinal aleatório; Inverno, Primavera, Verão, Outono. $VE = [P_{PAT\ I,P,V,O}(t), P_{PAT\ I,P,V,O}(t-24), P(t-23), P(t-24), P(t-25), P_{PAT\ I,P,V,O}(t-168), P(t-167), P(t-168), P(t-169), P_{RANDOM}(t)]$

Na figura 6-5 representa-se simbolicamente a constituição de VE referido à variante 7 das descritas anteriormente.

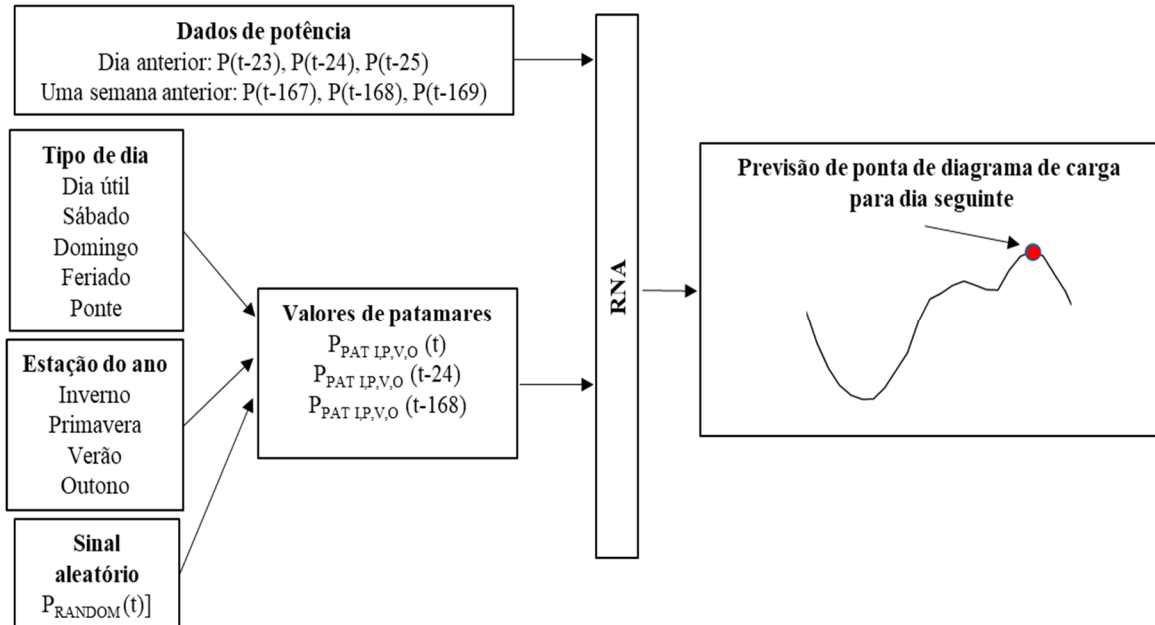


Figura 6-5: Composição do vector de entrada final para a previsão da ponta do diagrama de carga para o dia seguinte.

Para ter uma ideia geral dos resultados correspondentes a todas as configurações do VE, de 1 até 7, representam-se na figura 6-6 essas previsões sobrepostas. Neste caso foi seleccionado o mês de Março, caso de estudo - cidade de Lisboa.




Figura 6-6: Previsão de pontas diárias, Março 2015, Lisboa.

A previsão mensal para a cidade de Porto está ilustrada pela figura 6-7, e para a cidade de Évora – figura 6-8. Para mostrar a diferença de consumo em várias épocas do ano, foram escolhidos respectivamente os meses de Julho e de Dezembro.




Figura 6-7: Previsão de pontas diárias, Julho 2015, Porto.




Figura 6-8: Previsão de pontas diárias, Dezembro 2015, Évora.

A seguir apresentam-se alguns gráficos ilustrativos dos resultados de previsão das pontas depois de realizar os treinos e as simulações de rede. Foram representados dois diagramas de pontas: um, correspondente às cargas reais, e outra – às cargas previstas, resultado do modelo previsor, usando a configuração VE 7. A configuração 7 ficou privilegiada nessas ilustrações porque através dela que foi obtido o melhor desempenho do método previsor.

O gráfico comparativo mensal entre a ponta prevista (*load peak forecast*) e a ponta verificada (*load peak real*) para a cidade de Lisboa, seguido do gráfico da evolução da percentagem de erro, está ilustrado pelas figuras 6-9 e 6-10.




Figura 6-9: Previsão mensal de pontas, Outubro 2015, Lisboa.




Figura 6-10: Evolução da percentagem de erro relativa à figura 6-9.

Relativamente à previsão das pontas de diagrama de carga do mesmo mês de Outubro em toda a RNT, foram construídos os gráficos apresentados nas figuras 6-11 e 6-12. Os valores de MAPE obtidos são aceitáveis, considerando que para os problemas de previsões de pontas o valor máximo de MAPE não deve exceder 10% (este valor foi obtido junto do TSO).




Figura 6-11: Resultados da previsão para a RNT, Outubro 2015.




Figura 6-12: Evolução de percentagem de erro de previsão da figura 6-8.

O exemplo de comparação entre a ponta prevista e ponta real para o ano 2015 no caso da cidade de Évora está representado na figura 6-13.




Figura 6-13: Diagrama de pontas diárias de carga do ano 2015, Évora.

O valor de MAPE, obtido com o modelo proposto, para este período anual é igual a 4.35%. Para as cidades de Lisboa e Porto os valores de MAPE, são iguais a 2,2% e 2,74% respectivamente.

Os resultados obtidos são satisfatórios, comparáveis com os publicados na literatura sobre esta área (Zor, Timur, & Teke, 2017), (Abdurahmanov, Volodin, Zybin, & Ryabchenko, 2016), comprovando bom desempenho da nova abordagem proposta relativamente a composição do vector de entrada do modelo previsor.

6.3 CONCLUSÕES

A aplicação do método proposto à previsão de potências de ponta produziu resultados satisfatórios, dentro dos valores de erro aceitáveis e comparáveis com os obtidos por outros métodos e publicados na literatura especializada. Estes resultados confirmam a potencialidade do método proposto na aplicação generalizada às previsões de energia e potência dos SEE.



Previsão das cargas em ambiente de gestão da procura

Neste capítulo procede-se à descrição dos sistemas emergentes de gestão da procura e à análise da aplicação dos métodos de previsão de cargas em ambiente de tarifas dinâmicas.

7.1 INTRODUÇÃO

Conceptualmente, a participação dos consumidores na gestão da carga da rede eléctrica poderá beneficiar de forma global a operação do SEE.

Já actualmente se motiva o consumidor a gerir o seu consumo, no sentido de uniformizar a carga do sistema, penalizando o consumo nas horas de ponta e fomentando o consumo no período de vazio. Esta acção é conseguida através da diferenciação tarifária, em particular da tarifa regulada do acesso às redes. Esta diferenciação é usualmente definida pela divisão do dia em períodos tarifários, diferentemente, conforme se trate de dias úteis, sábados, domingos e feriados, Inverno, ou Verão, e aos quais corresponde uma tarifa distinta. Em Portugal Continental é o tarifário de ciclo semanal com 4 períodos tarifários: ponta, cheia, vazio normal e super vazio. Para pequenos consumidores existem ainda esquemas mais simples, sem diferenciação sazonal, ciclo diário, com dois, ou três, períodos tarifários (ERSE, 2017).

Os períodos tarifários são normalmente estáticos, estabelecidos para um período regulatório de vários anos. Na sua base estiveram os níveis de carga do diagrama de cargas do sistema, analisados num determinado período passado. Os horários dos períodos tarifários podem ser alterados, adaptando-se à evolução do diagrama de carga do sistema, mas essa alteração é quase sempre reactiva, em função do passado, com uma perspectiva estável no período regulatório seguinte.

Não existindo uma relação de dependência, no curto prazo, com a carga real do sistema, o benefício deste tipo de sistemas tarifários é limitado. O aumento da eficácia das medidas de DSM poderá ser obtido através de tarifas dinâmicas. A adopção de esquemas tarifários mais flexíveis, como por exemplo as tarifas dinâmicas, permite que a procura, incentivada por sinais de preço mais adequados aplicados nas circunstâncias críticas, de redes ou de produção, acompanhe as variações da oferta. As tarifas dinâmicas são constituídas pela definição de períodos críticos de abastecimento de energia, com tarifas elevadíssimas, baseada nas previsões de cargas. Normalmente estes períodos críticos são declarados com a antecedência de dois dias e têm uma duração variável. Para este efeito são utilizadas previsões de consumos de curto prazo.

Os valores de carga previstos, em função dos constrangimentos da produção, ou da rede eléctrica, podem indiciar situações de risco de abastecimento. Pretende-se, com as tarifas dinâmicas, uma resposta concertada dos consumidores no sentido reduzirem esse risco, reduzindo o seu consumo. O rigor da previsão assume especial importância pois o sinal de preço é assaz agressivo, multiplicando por várias vezes o preço médio da energia em períodos tarifários normais (não críticos). Estas tarifas, que se traduzem em penalizações, ou prémios, pela resposta adequada dos consumidores a sinais da operação do SEE, são estabelecidas, de entre um conjunto de regras pré-acordadas, com uma antecedência mínima (tipicamente, de 48 horas), em função do diagrama de carga previsto e da probabilidade que esse diagrama tenha de causar constrangimentos à exploração da rede.

A aplicação das tarifas dinâmicas, definida com um curto tempo de antecedência, tem a vantagem de se restringirem as penalizações a períodos temporais mais curtos. Com efeito, no exemplo do sistema tarifário português em vigor (ciclo semanal), o período de penalização mais forte, o período de horas de ponta, tem uma duração anual de aproximadamente 1000 horas. Os picos mais extremos na procura de energia eléctrica encontram-se tipicamente concentrados em 1% do total de horas durante o ano. A necessidade de satisfazer estes picos de carga obriga a que seja necessário construir centrais de pico que entram em operação com o único objectivo de satisfazer esses picos de, sendo por conseguinte a sua utilização bastante reduzida (i.e., cerca de 100 horas ao ano) (Faruqui, Harris, & Hledik, 2010). Resultado da sua reduzida utilização, estas unidades de produção são consideravelmente menos eficientes do que as utilizadas para alimentar a base do diagrama de carga.

As tarifas dinâmicas podem ainda ser aplicadas regional ou localmente, traduzindo melhor as especificidades dos diagramas de carga e as condições de exploração das redes locais e aumentando, por isso, a sua eficácia. Em Portugal iniciou-se um projecto-piloto de um sistema de tarifas dinâmicas, baseado na aplicação regional das penalizações (período de ponta crítica) com uma duração anual máxima de 100 horas (EDP Distribuição, 2018).

A eficácia de um sistema de tarifas dinâmicas está intimamente dependente do rigor da previsão dos diagramas de carga de curto prazo. O efeito das acções de DSM é tanto

mais benéfico, quanto o seu impacto no diagrama de carga for nos momentos reais de ponta da rede. Tendo o momento de definição da aplicação das penalizações uma antecedência mínima pré-definida (no caso português, 48 horas), este tem necessariamente que se basear em previsões de carga de curto prazo. É nesse sentido que o presente trabalho adquire maior importância, ao pretender atingir um maior rigor na previsão do diagrama de carga de curto prazo.

7.2 AVALIAÇÃO DOS MÉTODOS DE PREVISÃO DA POTÊNCIA DE PONTA EM AMBIENTE DE TARIFAS DINÂMICAS

Conforme foi referido no início deste capítulo a previsão das cargas de curto prazo é muito importante na aplicação de um sistema tarifário baseado em tarifas dinâmicas. Estas tarifas consistem na declaração de períodos críticos (tarifas mais elevadas) com uma antecedência curta, como um incentivo ao consumo para redução da ponta do sistema.

A fim de confirmar os ganhos de eficácia do método proposto, descrito nesta tese, foram avaliados os resultados das previsões simulando os seus efeitos em ambiente de tarifas dinâmicas e comparando-os com acções que seriam tomadas conhecendo antecipadamente o diagrama real dos consumos.

A avaliação foi efectuada, considerando dois sistemas de tarifas dinâmicas. O primeiro, considerando a definição dos períodos críticos cobrindo as horas de maior carga, sem qualquer restrição de localização ao longo dos dias. Este sistema é designado por ambiente sem restrições na definição dos períodos críticos. Tomou-se como referência que nesse ambiente de tarifas dinâmicas a duração anual dos períodos críticos é fixada em 100 horas. O segundo, considerando a definição dos períodos críticos conforme estabelecido no projecto-piloto de introdução de tarifas dinâmicas no sistema tarifário português (EDP Distribuição, 2018).

A avaliação tem por objectivo comparar diversas alternativas da composição do vector de entrada no modelo previsor, conforme descrito no Capítulo 6, procurando a melhor alternativa, em particular confirmando se a introdução dos diagramas de patamares e a injeção do sinal aleatório resultam em vantagens em relação à alternativa

do vector de entrada, composto sem estas abordagens e que será tomada como alternativa de referência.

7.2.1 AMBIENTE SEM RESTRIÇÕES NA DEFINIÇÃO DOS PERÍODOS CRÍTICOS

Para o primeiro ambiente de tarifas dinâmicas, onde a definição dos períodos críticos é efectuada sem restrições de localização no diagrama temporal, o parâmetro a comparar consiste na quantidade de coincidências temporais, em data e hora, das 100 maiores pontas de consumo previstas com as 100 maiores pontas do diagrama real do consumo. Ou seja, contaram-se quantas das 100 horas com maiores cargas previstas coincidiram com as 100 horas (data e hora) de maiores cargas do diagrama real de consumo.

No actual modelo de previsão o ano de 2014 foi utilizado para treino, e o ano 2015 - para simulação.

Os resultados, para os três casos de estudo, encontram-se reflectidos na tabela 7-1.

Tabela 7-1: Percentagens de coincidências das 100 horas de maior carga prevista com as 100 horas de maior carga real.

Rede	Previsão 1	Previsão 2	Previsão 3	Previsão 4	Previsão 5	Previsão 6	Previsão 7
Évora	55%	60%	50%	65%	58%	60%	59%
Lisboa	11%	52%	36%	56%	62%	48%	59%
Porto	45%	63%	58%	56%	59%	57%	54%

A designação das previsões é idêntica à utilizada para as alternativas de vector de entrada no Capítulo 6. A previsão 1 é a que corresponde ao método de referência, sem inclusão de patamares no vector de entrada das redes neuronais. As restantes previsões, de “Previsão 2” a “Previsão 7”, são variantes que utilizam o método proposto de inclusão de patamares no vector de entrada das RNA e que se diferenciam pela distinção da sazonalidade (nº de estações no ano), pela inclusão das séries de patamares diferidos e pela adição do sinal aleatório.

O valor em percentagem indica o número de vezes em que os momentos (data e hora) das 100 maiores cargas previstas em cada previsão coincidiram com os do

diagrama real. Nesta comparação não foram tomados em consideração os valores absolutos das cargas previstas.

Na figura 7-1, como exemplo, mostra-se que as horas de maior carga do diagrama real e previsto do mesmo caso de estudo coincidem só no dia 1, no segundo dia o valor da ponta é similar, mas a hora de ocorrência difere.




Figura 7-1: Coincidência das pontas dentro dum intervalo temporal (em tracejado) no dia 1, e não coincidência – no dia 2.

A figura 7-2 representa graficamente os resultados obtidos com a variante do método proposto. A abreviatura “Prev. s/patamares” corresponde a Previsão 1 da tabela 7-1. A “Melhor prev. c/patamares” significa a melhor das previsões entre Previsão 2, Previsão 3, ..., Previsão 7, da mesma tabela, quando o vector de entrada inclui os patamares de carga e o sinal aleatório.

De uma forma genérica em todos os casos de estudo, verificou-se uma melhoria dos resultados (maior número de coincidências) com a utilização do método proposto. As previsões que utilizam o método proposto têm maior número de coincidências de pontas, que variam entre 10 (caso de estudo Évora) a 51 p.p. (caso de estudo Lisboa).

Estes resultados significam que a utilização do método proposto é mais eficaz, aumentando a coincidência dos períodos críticos num ambiente de tarifas dinâmicas com os períodos de maior consumo do diagrama de cargas.




Figura 7-2: Comparação dos resultados dos métodos de previsão, em número de coincidências das 100 horas de maior carga face ao real.

7.2.2 AMBIENTE DE PROJECTO-PILOTO DE INTRODUÇÃO DE TARIFAS DINÂMICAS

No caso português, no âmbito do projecto de introdução de tarifas dinâmicas em curso (no texto oficial da Directiva da ERSE nº 6/2018, este corresponde ao Projecto-piloto 2), a declaração de períodos críticos é regida por um conjunto de regras mais restritivas (ERSE, 2018). Os períodos críticos não são declarados de forma avulsa nas horas previstas de maior carga, mas em períodos de 3 ou 5 horas, dentro de um intervalo fixo, nos dias de previsível maior carga, que se denominam dias críticos. O nº de dias críticos por ano não pode ser inferior a 16 e não pode ultrapassar 20. A duração dos períodos críticos é igual à duração do período de horas de ponta previsto nesse dia.

O intervalo em que é permitida a declaração de períodos críticos é o correspondente aos períodos de horas de ponta e cheias. Do conjunto destas condições resulta que os períodos críticos podem ser definidos em qualquer dia útil, das 07:00 às 24:00, independentemente da época do ano. Adicionalmente, em cada dia crítico só podem ser definidos dois períodos críticos com intervalo entre eles. Cada período crítico tem de ter uma duração superior a uma hora.

Nas simulações, tendo sido utilizada a informação do diagrama de cargas discretizada em períodos de uma hora, resulta que, num dia crítico, podem ser definidos períodos críticos numa das seguintes variantes: um único intervalo de 5 horas críticas, ou dois intervalos, 2+3 horas críticas, nas épocas do ano em que o tarifário estabelece 5

horas de ponta em cada dia útil, e um único intervalo de 3 horas críticas, na época do ano em que o tarifário estabelece 3 horas de ponta em cada dia útil.

As regras do projecto-piloto estabelecem ainda que a duração total dos períodos críticos, num ano deve encontrar-se entre 80 e 100 horas.

Estas medidas limitadoras em relação à definição dos períodos críticos constituem um compromisso de estabilidade do sistema tarifário. Se por um lado, para o sistema é mais conveniente definir os períodos críticos em função dos períodos de maior carga, para os consumidores é conveniente uma maior estabilidade dos períodos tarifários, reduzindo o nº de períodos críticos e limitando a sua localização no dia. Por outro lado, é conveniente manter o equilíbrio dos proveitos regulados, para o qual contribuem tarifas mais estáveis.

Na avaliação dos métodos alternativos em análise considerou-se que seriam definidos 20 dias críticos, correspondentes aos 20 dias com as pontas diárias mais elevadas. A avaliação foi feita de forma idêntica às 100 horas de cargas mais elevadas, comparando os 20 dias de maior ponta diária prevista (dias críticos) obtidos na previsão com os 20 dias de maior ponta do diagrama real de consumos e contando as coincidências.

Os resultados para os 3 casos de estudo encontram-se representados no gráfico da figura 7-3.




Figura 7-3: Comparação dos resultados dos métodos de previsão, em nº de coincidências dos 20 dias de maior ponta face ao real.

Os valores indicam, em percentagem, o nº de dias coincidentes no resultado de cada previsão com os dias do diagrama real. Também nesta avaliação, se verificou uma melhoria dos resultados (maior nº de coincidências) com a utilização do método proposto, o que reforça a sua mais-valia. Em média, a melhor previsão com patamares mais sinal aleatório acerta em quase 4 dias mais, que a previsão sem patamares.

Para além de um maior nº de coincidências nas datas dos dias críticos, as pontas diárias previstas na previsão com patamares também se aproximam mais das respectivas pontas diárias do diagrama real, na generalidade dos dias, em comparação com os resultados obtidos com a previsão sem patamares.

As figuras seguintes procuram traduzir essa característica, representando cada coluna a dimensão do consumo real/ previsto em cada método, em cada um dos 20 dias de pontas mais elevadas do diagrama de consumo real (os dias em que deveriam ser declarados períodos críticos). Nos dias de maior carga do diagrama real em que nenhuma das previsões acertou, não é representada qualquer coluna.

Na figura 7-4 compara-se a dimensão das pontas previstas pelas duas previsões, com as pontas do diagrama real, nos dias que coincidiram com os 20 dias de maior carga real, para o caso de estudo da cidade de Évora.




Figura 7-4: Comparação das pontas previstas e reais, caso de estudo da cidade de Évora.

Para além da previsão com patamares coincidir em mais um dia coincidente com os dias de ponta mais elevada, do que o resultado da previsão sem patamares, há mais dias (6/1, 20/1, 3/2, 4/2, 5/2, 10/2 e 11/2), quando ambas as previsões coincidiram, em que o valor da previsão com patamares se aproxima mais do valor das pontas reais, do que o valor da previsão sem patamares.

No caso de estudo de Lisboa, as vantagens do método com patamares são mais evidentes, conforme mostra a figura 7-5.




Figura 7-5: Comparação das pontas previstas e reais, caso de estudo da cidade de Lisboa.

O nº de dias previstos coincidentes com os dias de maiores pontas é significativamente maior na previsão com patamares (mais 7 dias), do que na previsão sem patamares. Também nos dias em que ambos os métodos coincidiram, o valor de ponta previsto com patamares é frequentemente mais próximo do valor real (6/1, 20/1, 22/1, 10/2 e 11/2).

O caso de estudo da cidade do Porto, cujo gráfico comparativo se mostra na figura 7-6 vem igualmente confirmar as vantagens do método com patamares mais sinal aleatório.




Figura 7-6: Comparação das pontas previstas e reais, caso de estudo da cidade de Porto.

São mais 3 os dias em que a previsão com patamares coincidiu com os dias de maior ponta real, comparativamente aos resultados do método sem patamares. Por outro lado, em todos os dias identificados pelos dois métodos e que coincidiram com os dias de maiores pontas reais, o valor da previsão com patamares foi sempre mais próximo do real, do que o obtido pela previsão sem patamares.

Num sistema de tarifas dinâmicas, desenhado como no projecto-piloto português, não basta prever os dias críticos. É ainda necessário prever em que intervalo vão ocorrer as cargas mais elevadas e definir os períodos críticos de acordo com as regras estabelecidas. De acordo com o tarifário adoptado no projecto-piloto de introdução de tarifas dinâmicas, o período de horas de ponta, em cada dia útil, é de 5 horas, nas épocas 1 e 2, e de 3 horas, na época 3. A definição dos períodos do ano correspondente a cada época depende da região. Para os 3 casos de estudo, a definição das épocas é a que se representa na tabela seguinte:

Tabela 7-2: Períodos associados a cada uma das épocas para determinação dos períodos horários do projeto de introdução de Tarifas Dinâmicas.

	Época 1	Época 2	Época 3
Évora	Julho a Setembro	Janeiro e Fevereiro	Restantes meses
Lisboa	Janeiro a Março	Novembro e Dezembro	Restantes meses
Porto	Janeiro a Março	Novembro e Dezembro	Restantes meses

A simulação desenvolvida de aplicação das previsões ao projecto de tarifas dinâmicas baseou-se no pressuposto de que os períodos críticos correspondiam exclusivamente às horas de maiores consumos, respeitando as regras acima indicadas. Os resultados são os indicados nas figuras 7-7, 7-8 e 7-9.

Para representar a comparação dos resultados obtidos entre a previsão de referência, sem patamares, e a previsão com patamares (escolhida a variante que produziu melhores resultados), foram construídos diagramas temporais, onde, no eixo das abcissas se dispuseram os 20 dias de maior carga do diagrama real de consumo do ano 2015, para cada caso de estudo. No eixo das ordenadas representam-se, para o diagrama real e para cada método, as barras correspondentes aos períodos de maior carga, em cada dia e que seriam declarados períodos críticos, de acordo com as regras estabelecidas.

Os 20 dias de maiores cargas do ano 2015, em cada caso de estudo, foram todos dias úteis e nos meses das épocas 1 ou 2, excepto um dia no caso da cidade de Lisboa, que ocorreu no mês de Junho, que é época 3 nesta região. À excepção deste dia, cujo período crítico terá a duração de 3 horas, num único intervalo, todos os restantes dias terão períodos críticos com a duração de 5 horas, alguns repartidos por dois intervalos de 2 + 3 horas. Os períodos críticos ocorrerão entre as 7:00 e as 24:00 horas, conforme estabelecido.

Os resultados para o caso da cidade de Évora estão representados na figura 7-7.

Na cidade de Évora, maioria dos períodos críticos ocorrem à noite, entre as 18:00 e as 23:00. Esporadicamente, ocorrem de manhã, ou ao início da tarde. Este tipo do diagrama de consumos está relacionado com um maior peso da componente doméstica no conjunto do consumo.




Figura 7-7: Comparação dos períodos críticos resultantes dos métodos de previsão com os resultantes do diagrama real, caso de estudo Évora.

Nenhuma das previsões previu essa situação coincidente com o diagrama real. A previsão com patamares apontou a ocorrência de pontas no período da manhã, mas não coincidiu nos dias em que tal ocorreu no diagrama real. Para um total de 6 dias, nenhuma das previsões previu a ocorrência de cargas de dimensão tal que conduzissem a que esses dias viessem a ser identificados como críticos. Nesses dias, apenas aparecem representadas as barras correspondentes ao diagrama real.

O nº de horas dos períodos críticos previstos com a previsão com patamares, coincidentes com os períodos críticos do diagrama real foi de 55, no total das 100 horas. Este nº é igual ao nº de horas de períodos críticos previstos com a previsão sem patamares, nas mesmas condições. Neste caso de estudo, a vantagem da previsão com patamares é que esta identificou mais um dia crítico, 13 dias críticos, do que a previsão sem patamares (12 dias críticos).

Nos restantes casos de estudo, a maior eficácia da previsão com patamares é mais evidente. A figura 7-8 representa a comparação dos períodos críticos resultantes das previsões com os do diagrama real para o caso da cidade de Lisboa.

No caso da cidade de Lisboa, observa-se generalizadamente a ocorrência de dois períodos de pontas em cada dia, um de manhã, maioritariamente entre as 10:00/ 11:00 e as 13:00/ 14:00, e outro, ao fim da tarde, entre as 18:00 e as 20:00/ 21:00. Exceções

foram os dias 15/1, 9/2, 10/2 e 29/6 (figura 7-8). Esta tipologia do diagrama está relacionada com o equilíbrio das componentes residenciais e de serviços (laborais) presentes na carteira de consumos da cidade de Lisboa.




Figura 7-8: Comparação dos períodos críticos resultantes dos métodos de previsão com os resultantes do diagrama real, caso de estudo Lisboa.

O nº de horas dos períodos críticos previstos pelo método com patamares, coincidentes com os períodos críticos do diagrama real foi também de 55, nº idêntico ao do resultado para o caso de estudo anterior. Este nº é muito superior ao resultante das previsões com o método sem patamares, que nas mesmas condições foi de 28. O nº médio de horas de períodos críticos previstos com as 6 variantes simuladas de patamares foi de 50,5, bastante superior ao do método sem patamares.

Por outro lado, a variante seleccionada do método com patamares identificou 15 dos 20 dias críticos, enquanto o método sem patamares identificou apenas 8 dias críticos, sendo este caso um exemplo da vantagem significativa do método de previsão com patamares.

O resultado comparativo do caso de estudo da cidade do Porto está representado na figura 7-9.




Figura 7-9: Comparação dos períodos críticos resultantes dos métodos de previsão com os resultantes do diagrama real, caso de estudo Porto.

À semelhança da cidade de Lisboa, no caso da cidade do Porto observa-se igualmente a ocorrência de dois períodos de pontas em cada dia crítico, um de manhã, maioritariamente entre as 10:00/ 11:00 e as 13:00/ 14:00, e outro, ao fim da tarde, entre as 18:00 e as 20:00/ 21:00. Excepções foram os dias 15/1, 16/1 e 13/2. Esta tipologia do diagrama está relacionada com o equilíbrio das componentes residenciais e de serviços ou industriais (laborais) presentes no *mix* de consumos da cidade do Porto.

O nº de horas dos períodos críticos previstos com o método com patamares, coincidentes com os períodos críticos do diagrama real foi de 54, menos uma que nos casos anteriores. Este nº é superior ao resultante das previsões com o método sem patamares, que nas mesmas condições foi de 34. No caso da cidade do Porto, nº médio de horas de períodos críticos previstos com as 6 variantes simuladas de patamares foi de 50,3, bastante idêntico ao caso da cidade de Lisboa e superior ao do método sem patamares.

Relativamente ao nº de dias críticos, a variante seleccionada do método com patamares identificou 13 dos 20 dias críticos, enquanto o método sem patamares identificou apenas 10 dias críticos.

Os resultados obtidos com a simulação das previsões pelos métodos com e sem patamares mostraram as vantagens da inclusão dos patamares e adição do sinal aleatório no vector de entrada das redes neuronais a que recorre o método de previsão considerado.

A maior eficácia obtida pelo método com patamares mais sinal aleatório na previsão dos consumos com vista a definir os períodos críticos de um sistema de tarifas dinâmicas, quer na forma mais directa de aplicação às horas de maiores cargas (100 horas, nos casos simulados), quer num sistema condicionado, como o regulamentado no projecto de introdução das tarifas dinâmicas em Portugal, evidenciam as vantagens e a mais-valia do trabalho realizado.

7.3 AVALIAÇÃO DO IMPACTO ECONÓMICO DA PREVISÃO NUM SISTEMA DE TARIFAS DINÂMICAS

O objectivo das tarifas dinâmicas consiste em promover junto dos consumidores acções que tendam ao alisamento do diagrama de cargas das redes. Essas acções são produzidas através de tarifas mais agressivas, que podem resultar num prémio, se o consumidor reagiu em conformidade com o sinal de redução do consumo, ou numa penalização, se o consumidor não teve reacção, ou actuou no sentido contrário.

A forma estabelecida no projecto de introdução das tarifas dinâmicas consiste em aplicar uma tarifa adicional à diferença entre a potência média de consumo nos períodos críticos (designados de ponta crítica) e a potência média dos restantes períodos de ponta (designados de ponta não crítica) estabelecidos no tarifário. Se a diferença resulta negativa (a potência média nos períodos de ponta crítica é menor que nos períodos de ponta não crítica), o que significa que o consumidor tem um consumo menor nos períodos críticos e, portanto, reagiu em conformidade com o sinal da tarifa, o consumidor recebe um prémio. Caso contrário tem uma penalização adicional na factura de energia eléctrica (ERSE, 2018).

A fim de avaliar o benefício do método proposto, compararam-se, para os 3 casos de estudo, os encargos resultantes da aplicação da tarifa de potência adicional em horas de ponta crítica, considerando a definição dos períodos críticos a partir do diagrama real

dos consumos e das previsões de carga obtidas com as diversas alternativas de composição dos vectores de entrada.

A tarifa de acesso às redes para a potência adicional em horas de ponta crítica constitui um sinal para os consumidores tomarem medidas de gestão do seu consumo (DSM), com vista ao objectivo de alisamento do diagrama de carga da rede. Entende-se que o valor do encargo resultante dessa tarifa seja equivalente ao custo adicional que o sistema tem de incorrer para garantir o abastecimento nas condições de carga sem a concretização de medidas de DSM.

Na valorização do encargo utilizou-se o valor da tarifa definido pela ERSE para o projecto de introdução das tarifas dinâmicas para consumos em AT, publicado em (EDP Distribuição, 2018), que é de 1,053 €/kW, por mês, ou seja, de 12,636 €/kW, por ano.

Tal como na análise realizada no ponto anterior, as comparações foram efectuadas para os dois ambientes de tarifas dinâmicas: primeiro, considerando a definição dos períodos críticos cobrindo as horas de maior carga, sem qualquer restrição de localização ao longo dos dias, segundo, considerando a definição dos períodos críticos conforme estabelecido no projecto-piloto de introdução de tarifas dinâmicas no sistema tarifário português (EDP Distribuição, 2018).

7.3.1 IMPACTO EM AMBIENTE SEM RESTRIÇÕES NA DEFINIÇÃO DOS PERÍODOS CRÍTICOS

No primeiro caso, para o diagrama de consumo real, calcularam-se separadamente a potência média nas 100 horas de maior consumo (potência média em horas de ponta crítica) e a potência média nas restantes horas de ponta estabelecidas no tarifário (potência média em horas de ponta não crítica). Para cada uma das previsões obtidas definiram-se as horas críticas como sendo as 100 horas de maior consumo previsto. De seguida, calcularam-se as potências médias do consumo real nas horas críticas definidas em cada previsão e nas restantes horas de ponta não crítica definidas pelo tarifário. As potências médias foram calculadas sempre considerando o diagrama de consumo real. As horas de ponta crítica e, por consequência, as restantes horas de ponta não crítica é que são diferentes, dependendo de cada previsão de cargas obtida.

O encargo da tarifa adicional em horas de ponta crítica é aplicado sobre a diferença entre as potências médias em horas de ponta crítica e não crítica.

Os resultados da simulação efectuada para o caso de estudo de Évora, relativa ao ano de 2015, encontram-se na tabela 7-3.

Tabela 7-3: Simulação de potências médias em horas críticas e não críticas e encargo de potência adicional em horas de ponta crítica no caso de Évora, ano 2015.

Caso de estudo Évora	Diagrama Real	Previsão s/ patamares	Melhor previsão c/ patamares mais sinal aleatório
Potência média horas de ponta não crítica [kW]	31.961	31.976	31.885
Potência média horas de ponta crítica [kW]	46.024	44.319	44.646
Encargo adicional em horas de ponta crítica [€/ano]	177.696 €	155.966 €	161.251 €

Para o caso de estudo de Évora e em função do diagrama real dos consumos, o valor do custo do sistema com as horas de ponta crítica é de 178 k€/ano. Num sistema tarifário de tarifas dinâmicas este valor é transmitido aos consumidores como sinal para tomarem medidas de DSM, que, adoptando-as, deixam de suportar esse encargo, não as adoptando, a factura energética fica mais elevada.

Como os períodos de ponta crítica são definidos com antecedência, necessariamente baseadas em previsões, os sinais transmitidos aos consumidores são os resultantes das previsões.

No caso de Évora, os sinais transmitidos seriam menores, que se traduziriam numa redução de eficácias das tarifas dinâmicas. Com a previsão de referência, sem patamares, o sinal seria reduzido em cerca de 12%. A eficácia da previsão com patamares é maior (redução face ao real de 9%), o que comprova a vantagem do modelo de previsão com patamares.

Os resultados da simulação efectuada para o caso de estudo de Lisboa, correspondente ao ano 2015, encontram-se na tabela 7-4.

Tabela 7-4: Simulação de potências médias em horas críticas e não críticas e encargo de potência adicional em horas de ponta crítica no caso de Lisboa, ano 2015.

Caso de estudo Lisboa	Diagrama Real	Previsão s/ patamares	Melhor previsão c/ patamares mais sinal aleatório
Potência média horas de ponta não crítica [kW]	449.448	451.832	449.826
Potência média horas de ponta crítica [kW]	601.198	544.599	586.222
Encargo adicional em horas de ponta crítica [€/ano]	1.936.457 €	1.172.208 €	1.723.494 €

Para o caso de estudo de Lisboa, o valor do custo do sistema com as horas de ponta crítica, baseado no diagrama real dos consumos, é de aproximadamente 1,9 M€/ano, dimensão muito superior em virtude da dimensão da carga. Os resultados obtidos na previsão sem patamares ficaram muito aquém das necessidades reais, reduzindo a eficácia de um eventual sistema de tarifas dinâmicas para 61%, com um sinal de 1,17 M€. Já os resultados obtidos com o melhor método com patamares permitiriam aumentar o sinal dado aos consumidores para 1,7 M€, menos 11% do que o real.

Os resultados da simulação efectuada para o caso de estudo do Porto, correspondente ao ano 2015, encontram-se na tabela 7-5. O valor real do custo do sistema com as horas de ponta crítica é de 759 k€/ano, em linha com a dimensão da carga. O resultado obtido na previsão sem patamares ficou-se pelos 678 k€/ano, reduzindo a eficácia do sinal aos consumidores para 89%. O resultado obtido com o melhor dos métodos com patamares permitiria aumentar o sinal dado aos consumidores para 710 k€, aproximando-se muito perto do valor obtido com o diagrama de consumo real (atingiu 94% deste).

Tabela 7-5: Simulação de potências médias em horas críticas e não críticas e encargo de potência adicional em horas de ponta crítica no caso do Porto, ano 2015.

Caso de estudo Lisboa	Diagrama Real	Previsão s/ patamares	Melhor previsão c/ patamares mais sinal aleatório
Potência média horas de ponta não crítica [kW]	200.306	200.660	200.208
Potência média horas de ponta crítica [kW]	260.362	254.340	256.403
Encargo adicional em horas de ponta crítica [€/ano]	758.863 €	678.311 €	710.080 €

A figura 7-10 mostra os graus de aproximação dos valores obtidos com as previsões aos obtidos com o diagrama real dos consumos, o que pode ser considerado o grau de eficácia dessas previsões.




Figura 7-10: Comparação do grau de eficácia dos resultados das previsões, face aos resultados baseados no diagrama real de consumos.

Em média, o grau de eficácia da melhor previsão com patamares aumenta em 3 a 28 p.p., face à previsão sem patamares. Embora não exista uma proporcionalidade directa entre o valor do custo para o sistema e a dimensão da carga, para que se possa estabelecer uma grandeza de avaliação de mais-valia, o valor médio do incremento proporcionado pelo modelo proposto é de 545 € por MW de potência média de ponta em horas críticas, por ano. Aplicando este valor à ponta da rede do continente, estimamos um impacto na tarifa da ordem dos 4 M€, por ano.

7.3.2 AMBIENTE DE PROJECTO-PILOTO DE INTRODUÇÃO DE TARIFAS DINÂMICAS

Na análise dos efeitos no segundo ambiente de tarifas dinâmicas, considerando a definição dos períodos críticos conforme estabelecido no projecto-piloto de introdução de tarifas dinâmicas no sistema tarifário português (ERSE, 2018), foram mantidos os mesmos princípios descritos no subcapítulo 7.2 de definição dos períodos críticos, de

que resultaram naturalmente diferentes períodos críticos para o diagrama real de consumos e para cada previsão simulada.

Calcularam-se as potências médias do consumo real em horas de ponta crítica para esses períodos críticos (diferentes para o diagrama real e para cada previsão). Considera-se que a definição dos períodos críticos é efectuada com base nas respectivas previsões, enquanto a aplicação da tarifa adicional é baseada no consumo real nesses períodos críticos. Em consequência da definição de períodos críticos diferentes, também as horas de ponta não crítica (que são as horas de ponta definidas no tarifário nos dias não críticos) são diferentes no diagrama de consumo real e em cada previsão. Daí a diferença, ainda que pequena, dos valores da potência média em horas de ponta não crítica do diagrama real e de cada previsão.

A análise comparativa foi efectuada para os três casos de estudo. Os resultados da simulação efectuada para o caso de estudo de Évora, relativa ao ano de 2015, encontram-se na tabela 7-6.

Tabela 7-6: Simulação de potências médias em horas críticas e não críticas e encargo de potência adicional em horas de ponta crítica no caso de Évora, ano 2015.
(Definição dos períodos de ponta crítica conforme projecto-piloto).

Caso de estudo Évora	Diagrama Real	Previsão s/ patamares	Melhor previsão c/ patamares mais sinal aleatório
Potência média horas de ponta não crítica [kW]	31.836	31.978	31.956
Potência média horas de ponta crítica [kW]	45.113	43.620	43.823
Encargo adicional em horas de ponta crítica [€/ano]	167.764 €	147.111 €	149.952 €

Os valores de potências médias em horas de ponta crítica e não crítica sofreram ligeiras alterações face aos resultados representados na tabela 7-3, dado que os períodos de ponta crítica também são diferentes e correspondem a potências menos elevadas. Sendo aplicado a uma diferença, o encargo adicional em horas de ponta crítica sofre alterações de valor mais expressivas, genericamente para menos, uma vez que as regras impostas para a definição de horas de ponta crítica leva a que sejam classificadas nesta classe horas com valores mais baixos de consumo, do que se fossem seleccionados sem limitações.

Ainda assim, os resultados confirmam uma ligeira melhoria do método com patamares, face ao método sem patamares.

Os resultados da simulação efectuada para o caso de estudo de Lisboa, correspondente ao ano 2015, encontram-se na tabela 7-7.

Tabela 7-7: Simulação de potências médias em horas críticas e não críticas e encargo de potência adicional em horas de ponta crítica no caso de Lisboa, ano 2015. (Definição dos períodos de ponta crítica conforme projecto-piloto).

Caso de estudo Lisboa	Diagrama Real	Previsão s/ patamares	Melhor previsão c/ patamares mais sinal aleatório
Potência média horas de ponta não crítica [kW]	443.444	446.746	443.359
Potência média horas de ponta crítica [kW]	592.193	555.920	582.336
Encargo adicional em horas de ponta crítica [€/ano]	1.879.600 €	1.379.529 €	1.756.108 €

A análise do caso de estudo de Lisboa, veio mais uma vez confirmar a vantagem do método com patamares, representando um ganho de eficácia significativo, quase 375 k€, face aos resultados do método sem patamares.

Os resultados da simulação efectuada para o caso de estudo do Porto, correspondente ao ano 2015, encontram-se na tabela 7-8. Embora menos expressivos, os resultados obtidos para o caso de estudo da cidade do Porto, também dão vantagem ao método com patamares mais sinal aleatório.

Tabela 7-8: Simulação de potências médias em horas críticas e não críticas e encargo de potência adicional em horas de ponta crítica no caso do Porto, ano 2015. (Definição dos períodos de ponta crítica conforme projecto-piloto).

Caso de estudo Lisboa	Diagrama Real	Previsão s/ patamares	Melhor previsão c/ patamares mais sinal aleatório
Potência média horas de ponta não crítica [kW]	198.737	199.223	199.088
Potência média horas de ponta crítica [kW]	259.088	253.906	255.329
Encargo adicional em horas de ponta crítica [€/ano]	762.595 €	690.970 €	710.658 €

O quadro geral do aumento da eficácia da melhor previsão com patamares mais sinal aleatório encontra-se representado na figura 7-11, através dos graus de aproximação dos valores dos encargos adicionais em horas de ponta crítica, obtidos com as previsões, aos obtidos com o diagrama real dos consumos.




Figura 7-11: Comparação do grau de eficácia dos resultados das previsões, face aos resultados baseados no diagrama real de consumos. (Definição dos períodos de ponta crítica conforme projecto-piloto.)

O grau de eficácia da melhor previsão com patamares mais sinal aleatório aumenta em 2 a 25 p.p., face à previsão sem patamares. Esta melhoria significa entre 2 a 375 k€ nas tarifas dinâmicas, nos casos de estudo analisados. À escala da rede eléctrica de Portugal continental, considerando a diferença média obtida nos 3 casos, proporcionalmente à potência de ponta, o impacto da vantagem do método com patamares e sinal aleatório pode ultrapassar os 3 M€, por ano.

7.4 CONCLUSÕES

Simulada nos três casos de estudo a aplicação das previsões obtidas com o modelo predictor desenvolvido à definição dos períodos críticos de um sistema tarifário dinâmico, concluímos que a inclusão no vector de entrada dos patamares e de um sinal aleatório potencia melhores resultados, ainda que com diferentes graus de melhoria, o

que se traduz num aumento da eficácia dessas tarifas, em média, de 12 p.p., por comparação com o modelo sem a inclusão desses patamares.

O resultado médio obtido com o modelo proposto aproxima-se do valor obtido com o diagrama real em 91% (erro inferior a 10%), considerando-se uma boa aproximação da previsão à realidade.

A percentagem média de coincidências das horas definidas como críticas, com o modelo de vector de entrada com patamares e adição de sinal aleatório aumenta cerca de 36%, em média face ao modelo sem patamares.

O rigor das previsões tem impacto significativo na aplicação de um sistema de tarifas dinâmicas, expresso pela melhor aproximação dos sinais transmitidos aos consumidores através da definição dos períodos críticos.

Com base na valorização efectuada pela ERSE no âmbito do projecto-piloto de introdução das tarifas dinâmicas no sistema tarifário português, foi estimado o impacto global (em Portugal Continental) da melhoria do rigor proporcionada pelo método proposto com patamares e sinal aleatório na eficácia da aplicação da tarifa de potência adicional em horas de ponta crítica, pelo aumento do sinal transmitido aos consumidores, em 3 a 4 M€, por ano.

Os resultados obtidos evidenciam assim as vantagens e as mais-valias do modelo predictor proposto, com patamares e sinal aleatório, na construção de um sistema eficaz de tarifas dinâmicas e desenvolvimento das medidas de DSM associadas.

Conclusões e Perspectivas de Trabalhos Futuros

8.1 PRINCIPAIS RESULTADOS E CONTRIBUTOS

Com o desenvolvimento das metodologias de auxílio à condução, nomeadamente da introdução do conceito de *smart grid*, a previsão de carga eléctrica de curto prazo (a 24 horas) tem um papel fundamental no planeamento, gestão e controlo das redes de energia eléctrica, sendo assim necessários modelos cada vez mais robustos, por forma a tornar estas previsões cada vez mais precisas.

Nesta dissertação é apresentado um modelo de previsão a 24 horas incluindo deste modo a previsão da ponta para o dia seguinte. A previsão da ponta é um auxiliar importante para o operador de sistema, seja para realização de acções de condução de redes e/ou acções de despacho, incluindo, claro está, a definição da reserva girante.

O modelo baseia-se nos algoritmos de Redes Neurais Artificiais em combinação com os padrões matemáticos (patamares) sazonais de carga, destinado a prever o consumo de energia para hora seguinte e para 24 horas seguintes.

Como casos de estudo foram usadas as subestações das cidades de Lisboa, Porto e Évora (a última cidade é pioneira nas *smart grids* em Portugal, com o projecto *InovGrid*).

Em termos do desempenho de previsão a vinte e quatro horas o modelo apresentou um desempenho aceitável. A metodologia uma vez treinada, consegue responder de uma forma eficiente e rápida. O modelo foi também testado com os dados de carga de Rede Nacional de Transporte mostrando um desempenho similar.

A análise de valores dos erros, entre os quais destacando o MAPE, mostrou que o modelo possui um bom desempenho, superando na maioria das vezes os demais modelos analisados. A introdução dos patamares bem como o sinal aleatório, resultaram numa melhoria do desempenho.

É usual em outras abordagens, a utilização das variáveis endógenas associadas a sinais periódicos (sinusoidais ou abordagens *wavelet*), contudo este tipo de abordagem fixa em certa medida frequências, o que em face do carácter tendencial, mais imprevisível do sinal, poderá em certas situações, como é o do caso de estudo apresentado, ter um desempenho inferior.

Nesta abordagem a introdução de um do perfil de patamares, associada a um sinal aleatório, apresenta um melhor desempenho.

Alguns outros aspectos de previsão de carga em redes de média tensão, como a ampliação do horizonte de previsão, serão realizados em trabalhos futuros.

Nos sistemas onde estão em vigor as tarifas dinâmicas, é possível gerir de uma forma mais eficiente o diagrama de consumo, mediante o envio de sinais tarifários (tarifas significativamente muito altas) com o objectivo de promover junto dos consumidores, acções de gestão da procura (DSM).

Num ambiente de tarifas dinâmicas a previsão das cargas assume especial importância, porquanto a definição dos períodos críticos, aos quais se aplicam as tarifas agressivas, são estabelecidos com antecedência, necessariamente em resultado de previsões de carga. O rigor dessas previsões é determinante na eficácia do sistema e na prossecução dos objectivos para que foi criado.

Também neste âmbito, a utilização do modelo previsor desenvolvido nesta dissertação aplicado em ambiente de tarifas dinâmicas trouxe uma melhoria significativa dos resultados, em termos da definição dos períodos críticos mais adequados à realidade e quantificada em valor monetário dos sinais tarifários adicionais a repercutir na gestão do consumo.

O modelo previsor proposto constitui assim uma ferramenta importante que pode ser utilizada com sucesso na aplicação das tarifas dinâmicas no SEE.

O caminho para o desenvolvimento do SEE, para o qual a presente dissertação contribui, é no sentido do aumento da sua sustentabilidade e da descarbonização do sector energético.

8.2 PUBLICAÇÕES

Do trabalho desenvolvido no âmbito desta dissertação, resultaram as publicações científicas que se apresentam seguidamente.

Publicações científicas em revistas:

S. Chemetova; P. J. Santos; M. Ventim-Neves, “Short Term Load Forecasting in Smart Grids: Case Study of the City of Évora”, *Journal of Information Systems Engineering & Management*, Volume 2, Issue 3, Article No: 18, August 2017, DOI: 10.20897/jisem.201718.

Publicações científicas em capítulos de livros:

S. Chemetova; P. J. Santos; M. Ventim-Neves, “Load Forecasting in Electrical Distribution Grid of Medium Voltage”, in *Technological Innovation for Cyber-Physical Systems*, The 7th Advanced Doctoral Conference on Computing, Electrical and Industrial Systems, Eds. L.M. Camarinha-Matos et al., SPRINGER, Germany, 2016, pp. 340-349, DOI: 10.1007/978-3-319-31165-4_33.

S. Chemetova; P. J. Santos; M. Ventim-Neves, “Next Day Load Forecast: A Case Study for the City of Lisbon”, in *Technological Innovation for Resilient Systems*, The 9th Advanced Doctoral Conference on Computing, Electrical and Industrial Systems, Eds. L.M. Camarinha-Matos et al., SPRINGER, Germany, 2018, pp. 62 – 70, DOI: 10.1007/978-3-319-78574-5_6.

Publicações científicas em conferências:

S. Chemetova; P. J. Santos; M. Ventim-Neves, “Load peak forecasting in different load patterns situations”, 10th International Conference on Compatibility, Power Electronics and Power Engineering (CPE-POWERENG), 2016, pp.148-151, DOI: 10.1109/CPE.2016.7544175.

S. Chemetova; P. J. Santos; M. Ventim-Neves, “Load forecasting as a computational tool to support Smart Grids”, The 12th Iberian Conference on Information Systems and Technologies (CISTI'2017), 2017, pp. 461–466, DOI: 0.23919/CISTI.2017.7975781.

8.3 PERSPECTIVAS DE DESENVOLVIMENTO FUTURO

O trabalho realizado com a presente dissertação constitui um valioso contributo para o desenvolvimento de trabalhos futuros de melhoramento da qualidade e aumento do rigor das previsões de cargas nos SEE. De entre muitos outros possíveis caminhos de desenvolvimento para trabalhos futuros, destacam-se os seguintes:

- ✓ Aplicação do modelo proposto em séries de outros horizontes de previsão, de médio e longo prazo.
- ✓ Aprofundamento do estudo da construção dos diagramas de patamares, optimizando a duração das estações do ano e a tipologia dos dias, adequada aos casos de estudo em presença.
- ✓ Aplicação da metodologia proposta à previsão de evolução dos consumos, segmentados por classes de consumidores (*clusters*), e posteriormente agregados por redes de distribuição.
- ✓ Integração da informação recolhida nos pontos de consumo, através de contadores inteligentes (*smart metering*), no âmbito das *smart grids*, na alimentação do modelo previsor proposto.
- ✓ Integração dos instrumentos de planeamento territorial da administração pública no modelo previsor de evolução dos consumos de energia.
- ✓ Análise de novas interdependências entre as variáveis de potência e as variáveis climáticas, procurando novas relações, mais complexas, que se traduzam numa correlação mais forte do que a obtida nos estudos até agora realizados.
- ✓ Introdução da nova abordagem desenvolvida para a caracterização tipológica dos dias (os diagramas de patamares) aplicada a outro tipo de metodologia de previsão do consumo de energia eléctrica.
- ✓ Aplicação da abordagem proposta a outros sistemas e projectos-pilotos de introdução de tarifas dinâmicas existentes noutras geografias, optimizando a definição dos períodos críticos.

Referências

- Abdurahmanov, A., Volodin, M., Zybin, E., & Ryabchenko, V. (2016). Forecasting Methods in Electricity Distribution Networks (review). *Russian Internet Journal of Electrical Engineering*, 3-23.
- Altran, A. (2005). *Aplicação de Funções de Base Radial em problemas de Previsão de Cargas Elétricas via Redes Neurais Artificiais*. Ilha Solteira: Universidade Estadual Paulista.
- Apolinário, I., N., F., Leite Garcia, A., O. P., Trindade, A., & Verdelho, P. (2006). Determination of time-of-day schedules in the Portuguese electric sector. *Power Engineering Society General Meeting* (pp. 18-22). Montréal: IEEE.
- Araújo, K., Vitti, B., Lotufo, A., & Lopes, M. (2010). Previsão de afluências utilizando redes neurais artificiais com o auxílio das toolboxes do matlab. *XVIII Congresso Brasileiro de Automática*, (pp. 2585-2591). Bonito-MS.
- Bernardino, R. J. (2013). *Alterações da rede elétrica nacional, provocadas pela introdução das energias renováveis*. Portalegre: IPP.
- Camarinha-Matos, L. M. (2010). *Scientific research methodologies and techniques*. Universidade Nova de Lisboa: PhD Program in Electrical and Computer Engineering.
- Cheepati, K., & Prasad, T. (2016). Performance Comparison of Short Term Load Forecasting Techniques. *International Journal of Grid and Distributed Computing*, 9(4), 287-302.
- Chemetova, S., Santos, P., & Ventim-Neves, M. (2017). Short Term Load Forecasting in Smart Grids: Case Study of the City of Évora. *Journal of Information Systems Engineering & Management*, 2(3).
- Chen, C., Tzeng, Y., & Hwang, J. (1996). The application of artificial neural networks to substation load forecasting. *Electric Power Systems Research*, 38, 153-160.
- DeLurgio, S. A. (1998). *Forecasting Principles and Applications*. Kansas City: McGraw-Hill.

- Dias, R. (2010). *Metodologia de Previsão de Carga de Longo Prazo de Energia Elétrica*. Fortaleza: UFC.
- EDP Distribuição. (2010). *Guia Técnico de Planeamento de Redes de Distribuição*. Lisboa: Direcção de Planeamento de Rede.
- EDP Distribuição. (2015). *Manual de Ligações à rede elétrica de serviço público*. Lisboa.
- EDP Distribuição. (2018). *Plano de Desenvolvimento e Investimento na Rede de Distribuição 2017-2021*. Lisboa.
- EDP Distribuição. (2018). *Projetos Piloto - Tarifas de Acesso às Redes*. Obtido em 2018, de <https://www.edpdistribuicao.pt/pt/rede/Pages/TarifasDinamicas.aspx>
- ERSE. (2009). *Manual de procedimentos do Gestor do Sistema*. Obtido de <http://www.erse.pt/pt/electricidade/regulamentos/operacaodasredes/Documents/Manual%20de%20Procedimentos%20do%20Gestor%20do%20Sistema.pdf>
- ERSE. (2016). *Rede Nacional de Transporte*. Obtido em 2016, de <http://www.erse.pt/pt/electricidade/actividadesdosector/transporte/Paginas/RedeNacionaldeTransporteRNT.aspx>
- ERSE. (2017). *Ciclo semanal opcional para os consumidores em MAT, AT e MT em Portugal Continental*. Obtido em 2017, de <http://www.erse.pt/pt/electricidade/tarifaseprecos/periodoshorarios/Paginas/CicloopcionalosconsumidoresMATATMT.aspx>
- ERSE. (2018). Aprovação das regras dos projetos-piloto de aperfeiçoamento da estrutura tarifária e de tarifas dinâmicas no Acesso às Redes em MAT, AT e MT em Portugal Continental. *Diário da República*, 6300-6321.
- European Commission. (2018). *Europe 2020 strategy*. Obtido em 2018, de https://ec.europa.eu/info/business-economy-euro/economic-and-fiscal-policy-coordination/eu-economic-governance-monitoring-prevention-correction/european-semester/framework/europe-2020-strategy_en
- European Parliament, Council of the European Union. (Abril de 2012). Directive 2012/27/EU of the European Parliament and of the Council on energy efficiency. *Official Journal of the European Union*.
- Fagundes, A. (2013). *Gestão do Deslastre de Cargas – Évora como caso de estudo*. Lisboa: ISEL.
- Fallah, S., Deo, R., Shojafar, M., Conti, M., & Shamshirband, S. (2018). Computational Intelligence Approaches for Energy Load Forecasting in Smart Energy Management Grids: State of the Art, Future Challenges, and Research Directions. *Energies*, 11(3).
- Farias, D. (2008). *Previsão da Carga de Energia Diária em Patamares Combinando Técnicas Estatísticas e de Inteligência Computacional*. PUC-Rio.

- Faruqui, A., Harris, D., & Hledik, R. (2010). Unlocking the €53 billion savings from smart meters in the EU: How increasing the adoption of dynamic tariffs could make or break the EU's smart grid investment. *Energy Policy*, 38, 6222 – 6231.
- Fayyad, U., Piatetsky-Shapiro, G., & Smyth, P. (1996). The KDD Process for extracting useful knowledge from volumes of data. *Communications of the Association for Computing Machinery*, 39(11), 27-34.
- Ferreira, P. (2012). *"InovGrid" - Redes inteligentes ao serviço da prosperidade renovável*. Setúbal.
- Ferreira, V. (2005). *Técnicas de regularização de modelos neurais aplicadas à previsão de carga a curto prazo*. Tese de Doutoramento, UFRJ.
- Fidalgo, J., & Lopes, J. P. (2005). Load forecasting performance enhancement when facing anomalous events. *IEEE Transactions on Power Systems*, 20(1), 408-415.
- Fidalgo, N., & Matos, M. (2007). Forecasting Portugal global load with artificial neural networks. *International Conference on Artificial Neural Networks*, (pp. 728-737). Porto.
- Figueiredo, R., Santos, J., & Cechin, A. (2009). Um novo sistema neural para previsão de carga em sistemas de energia eléctrica. *XLI SBPO 2009 - Pesquisa Operacional na Gestão do Conhecimento*, (pp. 274-285).
- Giacometto, F., Sala, E., Kampouropoulos, K., & Romeral, L. (2015). Short-Term Load Forecasting using Cartesian Genetic Programming: an Efficient Evolutive Strategy. Case: Australian electricity market. *41st Annual Conference of the IEEE Industrial Electronics Society IECON*, (pp. 5087-5094). Yokohama.
- Gomes, A. (2004). *Identificação e apoio à selecção de estratégias de controlo directivo de cargas. Uma abordagem multiobjectivo evolucionária*. Tese de Doutoramento, FCT-UC, Coimbra.
- Gross, G., & Galiana, F. (1987). Short term load forecasting. *IEEE Transactions on Power Systems*, 75(12), 1558-1573.
- Guirelli, C. (2006). *Previsão da carga de curto prazo de áreas eléctricas através de técnicas de inteligência artificial*. Tese de Doutoramento, Universidade de São Paulo.
- Hippert, H., Pedreira, C., & Sousa, R. (2001). Neural Networks for Short-Term Load Forecasting: A Review and Evaluation. *IEEE Transactions on Power Systems*, 16(1), pp. 44-55.
- Hong, T. (2015). *Load Forecasting Case Study*. Illinois Institute of Technology.
- Høverstad, B., Tidemann, A., Langseth, H., & Öztürk, P. ., (2015). Short-Term Load Forecasting With Seasonal Decomposition Using Evolution for Parameter Tuning. *IEEE Transactions on Smart Grid*, 6(4), 1904-1913.

- Huang, Z., Guo, H., Yang, P., & Xu, Z. (2017). Electricity load forecasting method for large consumers. *IEEE 3rd International Future Energy Electronics Conference and ECCE Asia*, (pp. 1703-1707). Kaohsiung.
- IPMA. (2016). *IPMA*. Obtido em 2016, de <https://www.ipma.pt/pt/index.html>
- Kaytez, F., Taplamacioglu, M., Cam, E., & Hardalac, F. (2015). Forecasting electricity consumption: A comparison of regression analysis, neural networks and least squares support vector machines. *Electrical Power and Energy Systems*, 67, 431-438.
- Kersting, W. (2007). *Distribution System Modeling and analysis*. CRC Press.
- Khatoun, S., Ibraheem, Singh, A., & Priti. (2014). Analysis and Comparison of Various Methods Available for Load Forecasting: An Overview. *International Conference on Innovative Applications of Computational Intelligence on Power, Energy and Controls with their Impact on Humanity*, (pp. 243-247). Ghaziabad.
- Kishita, Y., B., M., Giurco, D., Aoki, K., Yoshizawa, G., & Handoh, I. (2017). Designing backcasting scenarios for resilient energy futures. *Technological Forecasting & Social Change*, 124, 114-125.
- Lind, I., & Ljung, L. (2005). Regressor selection with the analysis of variance method. *Automatica*, 41(4), 693-700.
- Lopes, M. (2012). Método Híbrido utilizando os Modelos ARIMA e Redes Neurais Artificiais para Previsão de Cargas Eléctricas. *XXXIV Congresso Nacional de Matemática Aplicada e Computacional*, (pp. 795-796). Águas de Lindola, SP.
- López, M., Valero, S., Rodriguez, A., Veiras, I., & Senabre, C. (2018). New online load forecasting system for the Spanish Transport System Operator. *Electric Power Systems Research*, 154, 401-412.
- Lourenço, J., & Santos, P. (2012). Short-term load forecasting using a Gaussian process model: The influence of a derivative term in the input regressor. *Intelligent Decision Technologies*, 6(4), 273-281.
- Martins, J., Santos, P., Pires, A., Borges da Silva, L., & Mendes, R. (2007). Entropy-based choice of a neural network drive model. *IEEE Transactions on Industrial Electronics*, 54(1), 110-116.
- Matsumoto, M., & Nishimura, T. (1998). Mersenne Twister: A 623-Dimensionally Equidistributed Uniform Pseudo-Random Number Generator. *ACM Transactions on Modeling and Computer Simulation*, 8(1), 3-30.
- Moghran, I., & Rahman, S. (1989). Analysis and Evaluation of Five Short-term Load Forecasting Techniques. *IEEE Transactions on Power Systems*, 4(4), 1484-1491.

- OMIE. (2015). *Dados de mercado*. Obtido em 2015, de <http://www.datosdelmercado.omie.es/pt-pt/datos-mercado>
- Papalexopoulos, A., & Hesterberg, T. (Novembro de 1990). A Regression-based Approach to Short-term Load Forecasting. *IEEE Transactions on Power Systems*, 5(4), 1535-1550.
- Paretkar, P., Mili, L., Centeno, V., Kaiyan, J., & Miller, C. (2010). Short-term forecasting of power flows over major transmission interties: Using Box and Jenkins ARIMA methodology. *IEEE Power and Energy Society General Meeting*. Providence, RI.
- Park, H., Lee, B., Son, J., & Ahn, H. (2017). A comparison of neural network-based methods for load forecasting with selected input candidates. *IEEE International Conference on Industrial Technology (ICIT)*. Toronto, ON.
- Pereira, A. (2010). *Planeamento da expansão do sistema electroprodutor em ambiente de mercado*. Tese de Doutoramento, FEUP, Porto.
- Pessanha, J., & Justino, T. (2013). Um modelo para previsão de carga de curto-prazo. Obtido em 2016, de <https://www.aedb.br/seget/arquivos/artigos13/44218518.pdf>
- Rahman, S. (1990). Formulation and analysis of a rule-based short-term load forecasting algorithm. *Proceedings of the IEEE*, 78(5), pp. 805-816.
- Rasmussen, C., & Williams, C. (2006). *Gaussian Processes for Machine Learning*. MIT Press. Obtido em 2017, de <http://www.gaussianprocess.org/gpml/chapters/RW.pdf>
- REN. (2015). *Centro de Informação*. Obtido em 2015, de <http://www.centrodeinformacao.ren.pt/PT/InformacaoExploracao/Paginas/EstatisticaDiariaDiagrama.aspx>
- REN. (2016). *Estatística Diária - SEN*. Obtido em 2016, de <http://www.centrodeinformacao.ren.pt/PT/Paginas/CIHomePage.aspx>
- REN. (2017). *Centro de Informação*. Obtido em 2017, de <http://www.centrodeinformacao.ren.pt/PT/publicacoes/CaracterizacaoRNT/Caracteriza%C3%A7%C3%A3o%20da%20RNT%2031-12-2016.pdf>
- Rodrigues, R. (2014). *Previsão dos consumos na RNT considerando a produção distribuída – Desenvolvimento de um procedimento de apoio à decisão do Gestor do sistema*. Tese de Mestrado, FEUP, Porto.
- Rodygina, S., & Rodygin, A. (2016). Comparative Analysis of Electrical Load Forecasting Models of Industrial Plants. *Dynamics of Systems, Mechanisms and Machines*. Omsk, Russia: IEEE.
- Rosário, L. (2014). *Descrição do consumo de energia de consumidores industriais e comerciais utilizando descoberta de conhecimento em base de dados*. Tese de Mestrado, UNIVALI, Itajaí.

- Ryu, S., Noh, J., & Kim, H. (2017). Deep Neural Network Based Demand Side Short Term Load Forecasting. *Energies*, 10(1).
- Santos, P. (2005). *Previsão de cargas em horizonte de curto-prazo aplicada a subestações de distribuição*. Tese de Doutoramento, Universidade de Coimbra.
- Santos, P., Gomes, A., & Pires, A. (2003). On the use of reactive power as an endogenous variable in short-term load forecasting. *International Journal of Energy Research*, 27(5), 513-529.
- Santos, P., Martins, A., & Pires, A. (2004). Short-term load forecasting based on ANN applied to electrical distribution substations. *Universities Power Engineering Conference*, (pp. 427-432). Bristol, UK.
- Santos, P., Martins, A., & Pires, A. (2007). Designing the input vector to ANN-based models for short-term load forecast in electricity distribution systems. *Electrical Power and Energy Systems*(29), 338—347.
- Santos, P., Martins, A., Pires, A., Martins, J., & Mendes, R. (2006). Short-term load forecast using trend information and process reconstruction. *International Journal of Energy Research*, 30(10), 811-822.
- Santos, P., Rafael, S., & Pires, A. (2013). Load forecasting, the importance of the probability “tails” in the definition of the input vector. *International Conference on Power Engineering, Energy and Electrical Drives*. Istanbul: IEEE.
- Sousa, J., Neves, L., & Jorge, H. (2012). Assessing the relevance of load profiling information in electrical load forecasting based on neural network models. *Electrical Power and Energy Systems*, 40(1), 85-93.
- Sousa, R., Barros, M., & Miranda, C. (2006). Previsão horária de carga eléctrica usando Holt-Winters. *XXXVIII Simpósio Brasileiro de Pesquisa Operacional*, (pp. 575-584). Goiânia.
- Trudnowski, D., McCreynolds, W., & Johnson, J. (2001). Real-time Very Short-Term Load Prediction for Power System Automatic Generation Control. *IEEE Transactions on Control System Technology*, 9, 254-260.
- Tubino, D. (2007). *Manual de planeamento e controle da produção*. São Paulo: Atlas.
- Wan, J. (2003). *Nodal load estimation for electric power distribution systems*. Tese de Doutoramento, Drexel University.
- Willis, H., & Philipson, L. (2005). *Understanding Electric Utilities and Deregulation*. CRC Press.
- Woods, D. (2015). Four concepts for resilience and the implications for the future of resilience engineering. *Reliability Engineering and System Safety*, 141, 5-9.

- Yang, Y., Chen, Y., Yachen, Y., Li, C., & Li, L. (2016). Modelling a combined method based on ANFIS and neural network improved by DE algorithm: A case study for short-term electricity demand forecasting. *Applied Soft Computing*, 49, 663-675.
- Zor, K., Timur, O., & Teke, A. (2017). A State-of-the-Art Review of Artificial Intelligence Techniques for Short-Term Electric Load Forecasting. *6th International Youth Conference on Energy*. Budapest.

Anexos

ANEXO 1. DADOS FORNECIDOS PELO SISTEMA DE TELECONTAGEM DE EDP DISTRIBUIÇÃO

Neste anexo apresenta-se o excerto da tabela com as séries temporais de dados de carga (dados de potência média tomada activa) recolhidas do sistema de Telecontagem da EDP Distribuição, para o caso de estudo da cidade de Évora, contendo a informação relativa a duas subestações: SE Évora e SE Caeira.

Tabela 10-1: Potência média tomada activa recolhida relativa ao quatro transformadores das SE Évora e SE Caeira: as primeiras cinco horas de 1/1/2013.

DATA, HORA	ÉVORA TP1	ÉVORA TP2	CAEIRA TP1	CAEIRA TP2	PTT	PRE	Consumo Total
	[kW]	[kW]	[kW]	[kW]	[kW]	[kW]	[kW]
01-01-2013 00:15	11600	8960	0	3680	24240	0	24240
01-01-2013 00:30	11440	8800	0	3600	23840	0	23840
01-01-2013 00:45	11280	8720	0	3560	23560	0	23560
01-01-2013 01:00	11040	8640	0	3520	23200	0	23200
01-01-2013 01:15	10880	8480	0	3480	22840	0	22840
01-01-2013 01:30	10640	8240	0	3520	22400	0	22400
01-01-2013 01:45	10480	8000	0	3440	21920	0	21920
01-01-2013 02:00	9920	7760	0	3360	21040	0	21040
01-01-2013 02:15	9760	7680	0	3320	20760	0	20760
01-01-2013 02:30	9520	7440	0	3280	20240	0	20240
01-01-2013 02:45	9200	7280	0	3200	19680	0	19680
01-01-2013 03:00	8960	7200	0	3160	19320	0	19320
01-01-2013 03:15	8800	7200	0	3200	19200	0	19200
01-01-2013 03:30	8480	6960	0	3160	18600	0	18600
01-01-2013 03:45	8320	6800	0	3080	18200	0	18200
01-01-2013 04:00	8240	6720	0	3040	18000	0	18000
01-01-2013 04:15	7920	6560	0	3000	17480	0	17480
01-01-2013 04:30	7920	6640	0	2920	17480	0	17480
01-01-2013 04:45	7760	6480	0	2920	17160	0	17160
01-01-2013 05:00	7680	6480	0	2880	17040	0	17040

O significado das siglas da tabela:

TP 1 – Transformador de Potência 1

PTT – Potência Total de Transformação

TP 2 – Transformador de Potência 2

PRE – Produção em Regime Especial

O Consumo Total resulta da soma da Potência Total de Transformação e da Produção em Regime Especial. À data de recolha de informação, na zona urbana de Évora, praticamente não existia produção distribuída (centrais fotovoltaicas, nem eólicas ou mini-hídricas), daí a coluna “PRE” estar vazia. Os dados da potência reactiva (indutiva e capacitiva) e potência aparente não foram representados na tabela embora façam parte das leituras.

ANEXO 2. DADOS METEOROLÓGICOS

A tabela 10-2 apresenta um exemplo de séries temporais de dados meteorológicos recolhidos junto do IPMA - Instituto Português do Mar e da Atmosfera.

Tabela 10-2: Dados meteorológicos do IPMA, estação de Évora: os primeiros sete dias do ano 2012.

ANO	MÊS	DIA	T_MED	T_MAX	T_MIN	HR_MED	HR_MAX	HR_MIN	FF_MED	FF_MAX	RG_TOT
2012	1	1	8,9	13,0	3,9	94	100	72	1,7	6,7	4201,3
2012	1	2	9,5	15,0	4,6	88	100	53	2,4	8,5	8401,4
2012	1	3	7,7	14,1	1,9	86	100	56	2,2	7,9	10369,0
2012	1	4	9,1	16,2	3,2	81	98	52	2,8	7,8	10706,2
2012	1	5	7,6	12,2	4,2	97	100	82	2,8	8,5	8703,4
2012	1	6	8,4	14,7	5,2	88	100	55	2,5	7,2	10386,7
2012	1	7	9,7	17,8	4,4	75	95	45	2,7	7,8	10094,7

Legenda dos dados apresentados na tabela:

T_MED (°C) - Temperatura média do ar

T_MAX (°C) - Temperatura máxima do ar

T_MIN (°C) - Temperatura mínima do ar

HR_MED (%) - Humidade relativa média

HR_MAX (%) - Humidade relativa máxima

HR_MIN (%) - Humidade relativa mínima

FF_MED (m/s) - Intensidade média do vento

FF_MAX (m/s) - Intensidade máxima instantânea do vento

RG_TOT (KJ/m2) - Radiação global total